

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra informatiky

Analýza obrazu pomocí distančních transformací

Image Analysis using Distance Transforms

Zadání bakalářské práce

Student: **Tomáš Jemelka**

Studijní program: B2647 Informační a komunikační technologie

Studijní obor: 2612R025 Informatika a výpočetní technika

Téma: **Analýza obrazu pomocí distančních transformací**
Image Analysis using Distance Transforms

Jazyk vypracování: čeština

Zásady pro vypracování:

Měření vzdáleností mezi body v obraze se používá v mnoha oblastech analýzy obrazu jako např. detekce objektů či segmentace obrazu. Cílem práce je porovnat existující vzdálenosti, které se používají v oblasti analýzy obrazu, porovnat jejich úspěšnost na vybraných obrazech a zhodnotit jejich vhodnost použití pro určité třídy obrazů.

Ve své práci proveďte:

1. Představte existující metriky používané v analýze obrazu.
2. Vytvořte aplikaci, která transformuje obraz do vzdálenostní mapy na základě vybrané metriky.
3. Otestujte vzdálenosti na vybraných obrazech.
4. Zhodnot'te a porovnejte dosažené výsledky.

Seznam doporučené odborné literatury:

- [1] A. Protiere and G. Sapiro. *Interactive image segmentation via adaptive weighted distances*. Image Processing, IEEE Transactions on, 16(4):1046-1057, 2007
- [2] P. K. Saha, F. W. Wehrli, and B. R. Gomberg. *Fuzzy distance transform: Theory, algorithms, and applications*. Computer Vision and Image Understanding, 86(3):171-190, 2002
- [3] R. Strand, K. Ch. Ciesielski, F. Malmberg, and P. K. Saha. *The Minimum Barrier Distance: A Summary of Recent Advances*. Pages 57-68. Springer International Publishing, Cham, 2017
- [4] S. A. Nadeem, E. A. Hoffman, and P. K. Saha. *Path-gradient – a theory of computing full intensity-transition between two points*. In Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications, pages 399-407, Cham, 2018


Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí bakalářské práce: **Ing. Michael Holuša, Ph.D.**

Datum zadání: 01.09.2019

Datum odevzdání: 30.04.2020





doc. Ing. Jan Platoš, Ph.D.
vedoucí katedry



prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně. Uvedl jsem všechny literární
prameny a publikace, ze kterých jsem čerpal.

V Ostravě 15. května 2020

.....


Souhlasím se zveřejněním této bakalářské práce dle požadavků čl. 26, odst. 9 Studijního a zkušebního řádu pro studium v bakalářských programech VŠB-TU Ostrava.

V Ostravě 15. května 2020

..........

Rád bych na tomto místě poděkoval svému vedoucímu bakalářské práce panu Ing. Michaelu Holušovi, Ph.D. za odborné vedení, vstřícný přístup a cenné rady, které mi pomohly tuto práci zkompletovat.

Abstrakt

Tato bakalářská práce se zabývá představením a porovnáním existujících vzdáleností, které se používají v oblasti analýzy obrazu. Porovnávání je zaměřeno na metriky geodetické, rezistivní geodetické, k -max geodetické a minimální bariérové vzdálenosti, které jsou s pomocí knihovny OpenCV a jazyka C++ implementovány v programu pro aplikaci distanční transformace na obrazech z datasetu. Výsledným porovnáním poté byly ověřeny specifické vlastnosti jednotlivých metrik, jejich úspěšnost na vybraných obrazech a bylo provedeno zhodnocení jejich vhodnosti použití pro určité třídy obrazů.

Klíčová slova: Analýza obrazu, distanční transformace, měření vzdáleností, OpenCV, geodetická vzdálenost, k -max geodetická vzdálenost, rezistivní geodetická vzdálenost, minimální bariérová vzdálenost, segmentace obrazu měřením vzdáleností

Abstract

This bachelor thesis deals with the introduction and comparison of existing distances that are used in the field of image analysis. The comparison is focused on metrics geodesic, resistance-geodesic, k -max geodesic and minimum barrier distance, which are implemented with the help of OpenCV library and C++ in the final application for distance transformation of images from dataset. The resulting comparison verified the specific properties of each metric, their success rate on selected images and evaluated their suitability for certain classes of images.

Keywords: Image analysis, distance transform, distance measurement, OpenCV, geodesic distance, k -max geodesic, resistance-geodesic distance, minimum barrier distance, distance-based image segmentation

Obsah

Seznam použitých zkratk a symbolů	9
Seznam obrázků	10
Seznam tabulek	11
Seznam výpisů zdrojového kódu	12
Úvod	13
1 Základní informace	14
1.1 Obraz	14
1.2 Analýza obrazu	14
1.3 Segmentace	15
2 Distanční transformace	16
2.1 Měření vzdálenosti	17
2.2 Metriky určení vzdálenosti	17
2.2.1 Geodetická vzdálenost	18
2.2.2 k-max geodetická vzdálenost	19
2.2.3 Rezistivní geodetická vzdálenost	19
2.2.4 Minimální bariérová vzdálenost	21
3 Implementace	22
3.1 Knihovna OpenCV	22
3.2 Dataset obrazů	22
3.3 Zpracování obrazu	23
3.4 Implementace metrik distanční transformace	23
3.4.1 Geodetická vzdálenost	23
3.4.2 k-max geodetická vzdálenost	25
3.4.3 Minimální bariérová vzdálenost	26
3.5 Proces segmentace	28
3.6 Výpočet přesnosti segmentace	29
4 Výsledky testování	31
4.1 Testování metrik na umělých obrazech	31
4.2 Testování metrik na reálných obrazech	34
Závěr	45

Seznam použitých zkratek a symbolů

BSD	– Berkeley Software Distribution – licence pro svobodný software
DT	– Distanční transformace
MBD	– Minimum barrier distance - minimální bariérová vzdálenost

Seznam obrázků

1	Sémantická segmentace obrazu. [9]	15
2	Distanční transformace obrazu	16
3	Aplikace DT s využitím geodetické vzdálenosti.	18
4	Aplikace DT s využitím k -max geodetické vzdálenosti pro různé k	19
5	Aplikace DT s využitím rezistivní geodetické vzdálenosti pro různé hodnoty růstu funkce λ a prahové hranice t_c	20
6	Aplikace DT s využitím minimální bariérové vzdálenost.	21
7	Příklad sady společných obrazů v datasetu.	22
8	Příklad rozdělení zdrojových pixelů pro požadovaný obraz.	23
9	Segmentace měřením vzdálenosti z distančních map.	29
10	Obrazy pro určení přesnosti segmentace.	30
11	Výsledné segmentace po aplikaci metrik na umělém obraze se šumem.	31
12	Výsledné distanční mapy po aplikaci metrik na umělém obraze s problematikou malé hrany.	32
13	Výsledné distanční mapy po aplikaci metrik na umělém obraze s problematikou konstantní vzdálenosti.	33
14	Obrazy pro testování vlivu pozadí na DT.	35
15	Obrazy pro testování vlivu šumu v reálných obrazech.	37
16	Obrazy pro testování problematiky konstantní vzdálenosti v reálných obrazech. .	38
17	Obrazy pro testování vlivu pozice zdrojových pixelů na DT.	40
18	Obrazy, na kterých bylo nejvýhodnější využití rezistivní geodetické vzdálenosti. .	42
19	Obrazy, na kterých bylo nejvýhodnější využití MBD.	43
20	Obrazy, na kterých bylo nejvýhodnější využití k -max geodetické vzdálenosti. . .	44

Seznam tabulek

1	Chybovost příkladové segmentace 10a.	30
2	Průměrná chybovost metrik na celém datasetu.	34

Seznam výpisů zdrojového kódu

1	Algoritmus výpočtu geodetické vzdálenosti	24
2	Algoritmus výpočtu k -max geodetické vzdálenosti	25
3	Algoritmus výpočtu minimální bariérové vzdálenosti	27

Úvod

Analýza obrazu je rychle se rozvíjející vědní disciplína, jejímž cílem je získat a zpracovat informace z obrazu. Jedním z nástrojů pro získání požadovaných informací je distanční transformace. Aplikací distanční transformace na obraz získáme distanční mapy se vzdálenostmi mezi body v obraze dle použité metriky určení vzdáleností. Distanční mapy získané při distanční transformaci mají široké uplatnění například pro detekci objektů, segmentaci obrazu či analýzu medicínských obrazů.

V této práci budou nejprve představeny základní pojmy, jako je obraz a analýza obrazu, potřebné pro práci s distančními transformacemi, včetně představení segmentace obrazu, která je v této práci použita pro porovnání přesností distančních map. V další kapitole se práce bude zabývat popisem měření vzdálenosti a představením čtyř různých způsobů měření vzdáleností, které jsou v této práci vybrány pro porovnání. Mezi tyto metriky patří geodetická, rezistivní geodetická, k -max geodetická a minimální bariérová vzdálenost. Tyto metriky byly vybrány z toho důvodu, že geodetická a minimální bariérová vzdálenost jsou velmi často využívány v praxi a další dvě vznikly na VŠB - Technické univerzitě v Ostravě. Práce také bude obsahovat představení použitého datasetu obrazů a jeho zpracování pomocí knihovny OpenCV, popis způsobu, jakým byly metriky implementovány, představení procesu segmentace měřením vzdáleností na distančních mapách a popis výpočtu chybovosti získaných segmentací, které jsou poté využity při porovnávání přesností jednotlivých metrik.

V závěrečné části práce bude provedeno testování implementovaných metrik na umělých obrazech se zaměřením na vlastnosti jednotlivých metrik, ale také porovnání výsledků dosažených na reálných obrazech, včetně ověření představených vlastností a zhodnocení vhodnosti použití jednotlivých metrik pro určité třídy obrazů.

1 Základní informace

V této kapitole jsou popsány základní informace o samotných obrazech, jejich reprezentaci v digitální podobě a k čemu nám slouží jejich analýza včetně jejího využití v praxi. Dále je zde také představen pojem segmentace obrazu, základní způsoby segmentace včetně výběru způsobu, který je v této práci implementován a důležitost segmentace pro analýzu obrazu.

1.1 Obraz

Obraz je reprezentace vizuální informace, která je uložena v číselné podobě v paměti počítače, kde je takzvaně kvantován neboli rozdělen na jednotlivé malé elementy, které se nazývají pixely [1]. Rozdělením obrazu na pixely ovšem vytvoříme pouze jeho strukturu, ale pro jeho správné zobrazení a získání hodnot pixelů pro výpočty potřebujeme ještě jeden parametr a tím je hodnota intenzity jasu. Nejzákladnější je binární obraz, který je reprezentován jako 1-bitový obraz a dokáže uchovat pouze hodnoty pixelů 0-1. Nejčastějším způsobem uchování obrazu pro jeho analýzu je 8-bitový obraz tzv. šedotónní obraz, který reprezentuje u každého pixelu hodnotu 0-255 a umožňuje nám vykreslit obraz, který je složen pouze z odstínů šedé barvy. Poslední běžnou reprezentací je 24-bitový obraz, který v sobě zahrnuje 8-bitů pro každou barvu (červená, zelená a modrá) a dokáže tedy každé z barev přiřadit požadující hodnotu intenzity jasu 0-255 a vykreslit požadovaný obraz v plném barevném zobrazení. [2]

1.2 Analýza obrazu

Analýza obrazu je proces získávání informací z obrazu, zejména pak z digitálního obrazu, s použitím technik pro jeho zpracování. Samotná analýza obrazu je součástí mnohem větší oblasti práce s obrazem nazývanou zpracování obrazu, jejíž hlavním cílem je zlepšení vizuální kvality a manipulace se samotným obrazem. Od ostatních metod zpracování obrazu se analýza liší zejména tím, že jejím výstupem jsou číselné hodnoty nebo grafické informace, které reprezentují požadované charakteristiky vlastností obrazu pro jejich další klasifikaci. [3]

Existuje mnoho různých technik, které se pro analýzu obrazu využívají. Každá technika analýzy obrazu se specializuje na úzkou oblast problémů, a proto není možné určit techniku, která by měla využití pro širokou skupinu problémů a mohla by poskytovat úspěšné řešení pro problémy z více oblastí. Mezi nejznámější techniky analýzy obrazu patří zejména detekce objektů, segmentace obrazu, detekce pohybu a analýza medicínských obrazů. [4]

Počítačová analýza obrazu je nenahraditelnou součástí při zpracování velkého množství dat, pro úkoly, které ke správnému řešení vyžadují komplexní výpočty nebo pro získání kvantitativních informací. Ovšem také lidský zrak je mimořádně kvalitním prostředkem pro analýzu obrazu a získání informací vyššího řádu a díky tomu je stále nenahraditelnou součástí v oblasti zabezpečení a medicíny, ve kterých jej počítačová analýza stále nedokáže s úspěšností plně nahradit.

Z tohoto důvodu je velké množství nástrojů pro digitální analýzu obrazu, jako jsou například neuronové sítě nebo detekce hran, inspirováno lidským zrakem. [5]

1.3 Segmentace

Segmentace obrazu je technika využívána k analýze obrazu, jejímž úkolem je získat informace o oblastech zájmu, které slouží k rozpoznání objektů obrazu. Díky segmentaci dokážeme rozdělit obraz na oblasti pomocí přiřazování jednotlivých pixelů do odpovídajících skupin dle jejich charakteristik (barva, textura, intenzita jasu, odstín šedé, vzdálenost atd.). [6] Výsledkem segmentace je tedy obraz, který je rozdělen do segmentů, kde každý segment obsahuje pixely jedné charakteristiky. Typickým příkladem využití segmentace je rozdělení popředí a pozadí obrazu.

Segmentace je komplexní operace, která je ovlivněna všemi aspekty, které se mohou v obraze vyskytnout, jako například šum, slabý kontrast, nasvícení obrazu a nepravidelnosti v objektech. Z tohoto důvodu bylo vytvořeno mnoho různých způsobů rozdělení obrazu na segmenty. Mezi hlavní metody segmentace patří prahování [7], regionální metody [8], detekce hran [9], ale také metoda segmentace pomocí měření vzdálenosti s využitím distančních map [10] a právě proto v této práci aplikujeme měření vzdálenosti na segmentaci obrazu, viz kapitola 3.5. Komplexnější metody segmentace obrazu zahrnují segmentaci založenou na histogramu [11], interaktivní pohybové segmentaci [12], metodě shlukování [13] nebo segmentaci s pochopením scény obrazu nazývanou sémantická segmentace [14], viz obrázek 1.



Obrázek 1: Sémantická segmentace obrazu. [9]

2 Distanční transformace

V této kapitole si představíme pojem distanční transformace a její uplatnění v analýze obrazu. Dále také problematiku měření vzdálenosti v obrazech, využití této techniky pro analýzu a práci s obrazem a poté představíme metody distančních transformací, které se zabývají měřením vzdálenosti v obrazech a které jsme v této práci implementovali a použili pro porovnání úspěšnosti.

Distanční transformace (DT) je důležitým nástrojem počítačového vidění, analýzy, rozpoznání a zpracování obrazu. Jedná se o operaci, prováděnou na vstupním obraze, k určení vzájemné vzdálenosti pixelů. K obrazu, na který se DT aplikuje, přiřadíme distanční mapu, která v počátku obsahuje takzvané zdrojové (seed) pixely s výchozí vzdáleností 0 a všechny ostatní pixely, které nejsou označeny jako zdrojové, mají vzdálenost nekonečno, případně vhodně zvolené velké číslo [15], viz obrázek 2a. Zdrojové pixely se mohou určit jako jednotlivé body, hrany nebo případně i podle samotných objektů v obrazu. Výsledkem DT aplikované na obraz je šedotónní obraz (distanční mapa), který u všech nezdvojových pixelů obsahuje hodnoty reprezentující vzdálenost k nejbližšímu zdrojovému pixelu obrazu dle požadované metriky, viz obrázek 2b. [16]

∞	∞	∞	∞	∞	∞	∞	∞	∞	∞
∞	∞	∞	∞	∞	∞	∞	∞	∞	∞
∞	∞	∞	∞	0	0	∞	∞	∞	∞
∞	∞	∞	∞	0	∞	∞	∞	∞	∞
∞	∞	∞	∞	0	0	∞	∞	∞	∞
∞	∞	∞	∞	0	∞	∞	∞	∞	∞
∞	∞	∞	∞	0	∞	∞	∞	∞	∞
∞	∞	∞	∞	∞	∞	∞	∞	∞	∞
∞	∞	∞	∞	∞	∞	∞	∞	∞	∞
∞	∞	∞	∞	∞	∞	∞	∞	∞	∞

(a) Počáteční distanční mapa se zdrojovými pixely značenými vzdáleností 0.

6	5	4	3	2	2	3	4	5	6
5	4	3	2	1	1	2	3	4	5
4	3	2	1	0	0	1	2	3	4
4	3	2	1	0	1	2	3	4	5
4	3	2	1	0	0	1	2	3	4
4	3	2	1	0	1	2	3	4	5
4	3	2	1	0	1	2	3	4	5
5	4	3	2	1	2	3	4	5	6
6	5	4	3	2	3	4	5	6	7
7	6	5	4	3	4	5	6	7	8

(b) Výsledná distanční mapa se vzdálenostmi od zdrojových pixelů s využitím manhattanské vzdálenosti [17].

Obrázek 2: Distanční transformace obrazu

Výpočet vzdálenosti od skupiny zdrojových pixelů ke každému pixelu obrazu je globální operace. Pokud obraz, na který aplikujeme DT, není malých rozměrů, dochází k výraznému navýšení složitosti prováděných globálních operací a z tohoto důvodu využíváme algoritmy, které pracují pouze s určitým počtem sousedních pixelů, a i přesto nám stále poskytují správnou aproximaci vzdáleností. Tyto algoritmy dokáží určit globální vzdálenosti v obraze pomocí propagace lokálních vzdáleností neboli vzdáleností sousedních pixelů [16]. Bylo vyvinuto velké množství různých metrik pro distanční transformaci, které dosahují odlišných složitostí a přesností, přičemž v této práci se budeme zabývat vybranými z nich, viz kapitola 2.2.

2.1 Měření vzdálenosti

Pro měření vzdálenosti využíváme převedení obrazu do grafu $G = (V, E)$, kde každý vrchol V grafu odpovídá jednomu pixelu a hrany E spojující uzly představují spojení čtyř sousedních pixelů. Každá hrana E spojující dva vrcholy grafu obsahuje hodnotu, která symbolizuje cenu za použití této hrany při průchodu grafem. Cena hrany se v analýze obrazu označuje jako váha. Pro výpočet váhy hrany jsme v této práci použili vzorec

$$w_{i,j} = |b_i - b_j| + \eta \quad (1)$$

kde b_i, b_j jsou hodnoty jasu sousedních vrcholů V_i a V_j . Konstanta η určuje cenu použití této hrany a je nezbytná pro určení nenulové váhy hrany v případě shodného jasu pixelů. V této práci je při výpočtu váhy vždy použita hodnota $\eta = 10^{-3}$.

Nalezení nejkratší (nejlevnější) možné cesty mezi dvěma uzly je důležitým úkonem v teorii grafů a tento princip můžeme také využít u obrazů reprezentovaných grafy s váhami.

2.2 Metriky určení vzdálenosti

Zvolení vhodné metriky pro aplikaci procesu distanční transformace obrazu hraje velmi výraznou roli ve výsledné úspěšnosti a přesnosti výstupního šedotónního obrazu (distanční mapy) pro jeho další využití v analýze obrazu. Metrika slouží k určení, jakým způsobem získáme výslednou vzdálenost vrcholu grafu od zdrojového vrcholu. Při aplikaci distanční transformace na obraz nás tedy zajímá nejvýhodnější cesta od vrcholu ke zdrojovému vrcholu grafu dle použité metriky.

Cílem výpočtu vzdáleností v obraze je získat distanční mapu, která obsahuje charakteristiku daného obrazu, ve smyslu, že vzdálenosti pixelů od zdrojových pixelů se mění v závislosti na překážkách (hodnotách jasu nebo vah hran) na cestě ke zdrojovému vrcholu, díky čemu dokážeme obraz dále analyzovat a získat požadované informace (rozdělení popředí a pozadí, rozpoznání obrazu nebo hledání cesty v obraze). Za ideální DT se tedy dá považovat taková distanční mapa, ze které v dalších krocích (segmentaci, vizuální analýze, rozpoznání objektu apod.) získáme správné výsledky. V této práci můžeme za ideální DT považovat distanční mapu, jejíž pixely v rámci objektu mají nižší vzdálenost od zdrojových bodů objektu než od zdrojových bodů pozadí, z důvodu následné aplikace segmentace pomocí měření vzdáleností, viz kapitola 1.3.

Bylo představeno mnoho metrik, kde každá z nich přináší odlišný způsob pohledu na určení výsledné vzdálenosti. Příkladem je získání nejkratší vzdálenosti tradičním způsobem využitím Dijkstrova algoritmu [18], nejmenším rozsahem intervalu všech hodnot na cestě mezi vrcholy [19] nebo například pomocí Euklidovské vzdálenosti [20], která bere v úvahu pouze koncové vrcholy a ignoruje hrany mezi nimi, což ovšem není pro následnou analýzu dostačující.

2.2.1 Geodetická vzdálenost

Často využívanou metrikou je geodetická vzdálenost [21], která vypočítává vzdálenost po povrchu obrazu, kde hodnota jasu pixelu představuje výšku daného vrcholu grafu obrazu, kterou je nutno překonat. Geodetická vzdálenost tedy bere v úvahu pomyslné zakřivení obrazu, pomocí výškových rozdílů, podobnému jako při měření vzdálenosti na Zemi.

Mějme graf $G = (V, E)$, který obsahuje vrcholy A , B a cestu $P = (v_{p1}, v_{p2}, v_{p3}, \dots, v_{pn})$, propojující vrcholy A a B , kde v_{pi} jsou vrcholy, kterými cesta prochází. v_{p1} odpovídá vrcholu A a v_{pn} vrcholu B . Geodetická délka cesty je součet všech vah hran, kterými cesta prochází, udávána vzorcem

$$l_g(P) = \sum_{i=1}^{n-1} w_{(p_i, p_{i+1})}, \quad (2)$$

kde váhu hrany sousedních vrcholů $w_{(p_i, p_{i+1})}$ získáme pomocí vzorce (1). Budiž P_{AB} množina všech cest mezi vrcholy A a B . Výsledná geodetická vzdálenost je definována jako minimální cesta z množiny všech cest P_{AB} mezi vrcholy A a B

$$d_g(A, B) = \min_{P \in P_{AB}} l(P). \quad (3)$$



(a) Vstupní obraz se zdrojovými pixely značenými modrou barvou.



(b) Distanční transformace obrazu.

Obrázek 3: Aplikace DT s využitím geodetické vzdálenosti.

Ilustrace 3 obsahuje příklad aplikace této metriky včetně výsledné distanční mapy. I přestože je geodetická vzdálenost často využívána v různých oblastech analýzy obrazu, potýká se s problémem, kterým je obrazový šum, což bylo ukázáno v článcích [22] a [23]. Při jejím použití na obraze s velkým šumem dochází k nepřesným výsledkům díky tomu, že nedokážeme rozpoznat, zda se vzdálenost vrcholu skládá ze součtu velkého počtu malých rozdílů hodnot jasu nebo zda došlo k přechodu mezi pixely s výrazně odlišnými hodnotami jasu. Tento problém dokáže výrazně ovlivnit výsledky DT, které se následně mohou projevit v segmentaci obrazu, viz kapitola

1.3, a proto existují metriky, které se snaží o úspěšnou DT obrazu s výskytem šumu a vylepšit určení cest geodetické metriky.

2.2.2 k -max geodetická vzdálenost

Metrikou, která se snaží vylepšit distanční transformaci obrazu se šumem je k -max geodetická vzdálenost [22]. Vzdálenost dvou vrcholů, při použití k -max metriky, reprezentuje součet k nejvyšších vah hran grafu na cestě mezi těmito vrcholy, přičemž výsledná k -max geodetická vzdálenost mezi těmito vrcholy je cesta s nejmenším součtem těchto hran.

Budiž $\sum_{top_k}(\cdot)$ součtem k nejvyšších hodnot v kolekci obsahující váhy hran. Délka cesty je definována jako součet k nejvyšších vah, které tato cesta obsahuje dle

$$l_{km}(P) = \sum_{top_k} (w_{(p_1,p_2)}, w_{(p_2,p_3)}, \dots, w_{(p_{n-1},p_n)}), \quad (4)$$

kde P je cesta. Mějme množinu P_{AB} obsahující všechny cesty mezi vrcholy A a B v grafu. Výslednou k -max geodetickou vzdálenost mezi vrcholy A a B získáme dle


$$d_{km}(A, B) = \min_{P \in P_{AB}} \{l_{km}(P)\}. \quad (5)$$



(a) Vstupní obraz se zdrojovými pixely.



(b) Distanční transformace pro $k = 1$.



(c) Distanční transformace pro $k = 5$.



(d) Distanční transformace pro $k = 15$.

Obrázek 4: Aplikace DT s využitím k -max geodetické vzdálenosti pro různé k .

Na ilustraci 4 jsou vypočteny distanční transformace pro různé hodnoty k , kde je znázorněno ovlivnění transformace proměnnou k . Pro hodnotu $k = 1$ tato metrika bere v úvahu pouze nejvyšší hodnotu váhy cesty a nazýváme jí max-arc vzdálenost. Při použití hodnot $k \rightarrow \infty$ získáváme výsledek jako při použití geodetické vzdálenosti.

2.2.3 Rezistivní geodetická vzdálenost

Další metrikou v této práci je rezistivní geodetická vzdálenost [24], která je založena na spojení geodetické vzdálenosti [21] a rezistivní vzdálenosti [25, 26]. Cílem této metriky je redukce šance na použití chybné a nežádoucí cesty pro výpočet výsledné vzdálenosti. Při výpočtu vzdálenosti

využívá principu vodivosti, získané pomocí inverze vzorce (1) v kapitole 2.1. Tato váha je poté převedena na vodivost pomocí vzorce

$$c_{i,j} = e - \frac{\|w_{i,j}\|^2}{2\sigma_c^2}, \quad (6)$$

kde $w_{i,j}$ reprezentuje váhu hrany získané inverzí vzorce (1) a σ_c je konstanta. Mějme vektor potenciálů vrcholů f a vektor možných vnějších proudů do/z vrcholů r . Použitím Kirchhoffova zákona získáme vzorec

$$Lf = r, \quad (7)$$

kde L je Laplaceova matice obsahující vodivost $c_{i,j}$ na pozici i, j . Na pozici i, i obsahuje L záporný součet všech ostatních hodnot řádku i . Díky L je možné vypočítat efektivní rezistivitu, kde pokud proud vrcholu vstupuje do vrcholu i a poté vystupuje z vrcholu j , je efektivní rezistivita odpovídající potenciálu mezi i a j .

Pro odstranění problematiky součtu velmi malých vah na cestě je u této metriky použita prahová hodnota, která určuje minimální efektivní vodivost hrany grafu, která bude použita pro výpočet vzdálenosti. Hranám, které dosahují efektivní vodivosti nižší než je prahová hodnota, je přiřazena cena za použití této hrany nekonečno a hranám, které dosahují hodnot vyšších než prahová hodnota, je přiřazena cena nula. Výsledná váha hrany grafu spojující dva vrcholy je dána vzorcem

$$w_{i,j} = \frac{1}{1 + e^{\lambda(c_{i,j} - t_c)}}, \quad (8)$$

kde $c_{i,j}$ je efektivní vodivost mezi vrcholy i a j , t_c je prahová hodnota a λ reprezentuje rychlost růstu sigmoidní funkce. Rezistivní geodetická vzdálenost vrcholů A a B váženého grafu $G = (V, E)$ je poté vypočtena jako nejkratší cesta mezi těmito vrcholy. Ilustrace 5 obsahuje příklad aplikace této metriky včetně výsledných distančních map s ohledem na volbu parametrů λ a t_c .



(a) Vstupní obraz se zdrojovými pixely.



(b) $t_c = 0.7, \lambda = 1$



(c) $t_c = 0.7, \lambda = 30$



(d) $t_c = 1.1, \lambda = 2$

Obrázek 5: Aplikace DT s využitím rezistivní geodetické vzdálenosti pro různé hodnoty růstu funkce λ a prahové hranice t_c .

2.2.4 Minimální bariérová vzdálenost

Poslední metrikou, kterou jsme v této práci využili, je minimální bariérová vzdálenost (MBD) [19]. Vzdálenost dvou vrcholů A a B grafu $G = (V, E)$ je velikost nejmenšího intervalu, který obsahuje všechny váhy hran (hodnoty jasů), na cestě mezi těmito vrcholy. Pro určení MBD dvou vrcholů nám tedy stačí znát hodnotu nejvyšší a nejnižší váhy (jasu) na cestě mezi těmito vrcholy. Výslednou MBD mezi vrcholy A a B získáme jako

$$d_{mbd}(A, B) = \max(P_{AB}) - \min(P_{AB}). \quad (9)$$

kde $\max(P_{AB})$ představuje maximální jas a $\min(P_{AB})$ minimální jas na cestě P_{AB} mezi vrcholy A a B . [27]



(a) Vstupní obraz se zdrojovými pixely.



(b) Distanční transformace obrazu.

Obrázek 6: Aplikace DT s využitím minimální bariérové vzdálenost.

Ilustrace 6 obsahuje příklad aplikace této metriky včetně výsledné distanční mapy. Minimální bariérová vzdálenost se liší od ostatních způsobů měření vzdáleností zejména tím, že minimální velikost intervalu vah může být konstantní až do chvíle, kdy se na cestě mezi vrcholy A a B vyskytne nová minimální nebo maximální bariéra. Díky těmto odlišnostem je MDB poměrně odolná proti obrazovému šumu, rozmazání a závislosti na poloze zdrojových pixelů. [19]

3 Implementace

V této kapitole je představena knihovna OpenCV a dataset obrazů, který byl v této práci použit při testování metrik. Dále je zde také představen způsob, jakým se v knihovně OpenCV obraz zpracovává, implementace metrik v jazyce C++, proces segmentace obrazu z distančních transformací a odlišné metriky pro výpočet přesnosti této segmentace.

3.1 Knihovna OpenCV


Nejznámější a zároveň nejpoužívanější knihovnou s otevřeným kódem (open source) pro počítačové vidění, analýzu obrazu, strojové učení a operace nad obrazem v reálném čase je OpenCV (Open Source Computer Vision Library). Tato knihovna je publikována pod licencí BSD a je tudíž použitelná zdarma pro akademické i komerční užití. OpenCV poskytuje rozhraní pro jazyky C++, C, Python, Java a MATLAB a je možno ji použít na různých operačních systémech a platformách (Windows, Linux, Mac OS, iOS a Android). [28]

3.2 Dataset obrazů

Dataset obrazů, který je použit v této práci, byl představen v publikaci Geodesic Star Convexity for Interactive Image Segmentation [29]. Dataset se skládá ze 151 obrazů, přičemž obrazy byly vybrány ze tří různých dostupných datasetů GrabCut, Pascal VOC [30] a Alpha matting [31]. Pro každý obraz nám tento dataset poskytuje samotný barevný obraz, zdrojové pixely pro distanční transformaci a ideální segmentaci požadovaného objektu, viz ilustrace 7.



(a) Obraz datasetu



(b) Zdrojové pixely obrazu



(c) Ideální segmentace požadovaného objektu

Obrázek 7: Příklad sady společných obrazů v datasetu.

Obrázek 7a je samotný obraz, který budeme zpracovávat. Obrázek 7b obsahuje zdrojové pixely, které jsou využity při aplikaci procesu DT na obraz 7a. Tyto zdrojové pixely jsou znázorněny dvěma barvami (červená a bílá), kde červené pixely použijeme jako zdrojové pixely pro DT pozadí a bílé pixely pro DT popředí neboli požadovaného objektu obrazu. Obrázek 7c znázorňuje takzvaný ground truth (ideální segmentace) požadovaného objektu z obrazu 7a. Jedná se o dokonalou segmentaci, která přesně odpovídá objektu vyskytujícímu se v 7a a slouží k porovnání výsledné segmentace pro výpočet její úspěšnosti a přesnosti v kapitole 3.6.

3.3 Zpracování obrazu

Pro zpracování obrazu a jeho následnou analýzu je použita knihovna OpenCV, představená v kapitole 3.1 a programovací jazyk C++. Mějme tedy vstupní obraz z datasetu včetně jeho pomocných obrazů, viz ilustrace 7, kde nejprve načteme samotný obraz a převedeme jej do 8-bitového šedotónního obrazu. Dále je potřeba také zpracovat pomocný obraz se zdrojovými pixely popředí a pozadí, které je nutno rozdělit. Po načtení pomocného obrazu se zdrojovými pixely, viz 7b, jej procházíme sekvenčně a hledáme pixely označené jako zdrojové. Díky barevné odlišnosti zdrojových pixelů dokážeme pixely rozdělit, kde pixely s modrou barvou reprezentují zdrojové pixely pro pozadí a pixely s červenou barvou zdrojové pixely pro objekt. Po aplikaci procesu odlišení zdrojových pixelů získáme dva obrazy obsahující pouze zdrojové pixely popředí nebo pozadí, viz ilustrace 8, které použijeme při implementaci metrik společně se vstupním šedotónním obrazem, viz kapitola 3.4.



Obrázek 8: Příklad rozdělení zdrojových pixelů pro požadovaný obraz.

3.4 Implementace metrik distanční transformace

V této podkapitole jsou představeny jednotlivé algoritmy pro výpočet distančních transformací dle využití metriky. U uvedených algoritmů jsou přiloženy zkrácené pseudokódy a popis jejich průběhu. Implementace rezistivní geodetické vzdálenosti není v této podkapitole popsána a její zdrojové kódy nejsou součástí přílohy, avšak její algoritmus odpovídá algoritmu geodetické vzdálenosti, viz kapitola 3.4.1, s váhami hran dle kapitoly 2.2.3.

3.4.1 Geodetická vzdálenost

Při implementaci geodetické vzdálenosti jsme v této práci vzali v úvahu dva druhy propagace vzdáleností v obraze. První algoritmus, představen v článku [32], k propagaci vzdáleností využívá frontu, kdežto druhý algoritmus, představen v článku [33], propaguje vzdálenosti mezi sousedy dopředným a zpětným průchodem celého obrazu. Z těchto dvou algoritmů jsme poté vybrali implementaci s pomocí fronty z důvodu dosažitelnosti lepších výsledků v kratším čase představených v již zmíněném článku.

```

1  Vstup: Graf  $G=(u,w)$ , matice zdrojových pixelů
2  S~Výstup: Distanční mapa  $D$ 
3  GD( $G,S$ ):
4       $D[u] := \text{inf}$     //Nastavení počátečních vzdáleností na nekonečno
5       $D[s] := 0$         //Nastavení hodnot na pozicích zdrojových pixelů
6      Prioritní fronta  $Q$  jako min-halda
7       $Q.\text{push}(u \in S)$  //Naplnění fronty zdrojovými pixely
8
9      while  $Q$ -neprazdna do
10          $C := Q.\text{pop}()$ 
11          $C.\text{navstiven} := \text{True}$ 
12
13         for  $N$  in sousedniUzly[ $C$ ] do
14             //Pokud byl již tento uzel součástí fronty můžeme jej přeskočit
15             if  $N.\text{navstiven}$  then
16                 continue
17             //Nová vzdálenost sousedního pixelu přidáním váhy hrany
18              $\text{newVzdalenost} := D[C] + w(N)$ 
19
20             if ( $\text{newVzdalenost} < D[N]$ ) then
21                  $D[N] := \text{newVzdalenost}$ 
22                  $Q.\text{push}(N)$ 
23     return  $D$ 

```

Výpis 1: Algoritmus výpočtu geodetické vzdálenosti

1. V prvním kroku nastavíme počáteční hodnoty vzdáleností výsledné distanční mapy D na nekonečno, kromě hodnot na pozicích zdrojových pixelů, které mají počáteční hodnoty $D[s] = 0$.
2. Poté vytvoříme frontu Q , implementovanou jako min-haldu, kterou naplníme zdrojovými pixely (uzly) u grafu $G = (u, w)$, označenými v matici zdrojových pixelů S . Tyto uzly obsahují své souřadnice i, j v obrazu a hodnotu vzdálenosti od zdrojových pixelů, dle které je fronta řazena.
3. V dalším kroku z fronty Q vytahujeme vždy první uzel C s nejmenší hodnotou vzdálenosti a nastavíme jeho atribut navštívenosti na hodnotu **True**.
4. Poté procházíme všechny sousední uzly N uzlu C . Pokud byl sousední uzel N již součástí fronty Q (atribut uzlu $N.\text{navstiven}=\text{True}$), získali jsme jeho výslednou vzdálenost a mů-

žeme jej přeskočit. U uzlů, které ještě nebyly součástí fronty, vypočteme novou vzdálenost `newVzdalenost` přičtením váhy hrany mezi uzly N a C k současné vzdálenosti uzlu C .

5. V posledním kroku porovnáme novou vzdálenost `newVzdalenost` sousedního uzlu se vzdáleností, která je zaznamenána na jeho pozici v distanční mapě D . Pokud je nová vzdálenost menší, než současná výsledná hodnota v distanční mapě, přepíšeme tuto hodnotu $D[N] = \text{newVzdalenost}$ a sousední uzel N vložíme do prioritní fronty Q . [33]

3.4.2 k-max geodetická vzdálenost

Pro implementaci této metriky jsme využili zdrojový kód, představen autory v článku [22], který je volně dostupný. Při výpočtu k -max vzdálenosti nelze použít Dijkstrův algoritmus pro nalezení nejkratší cesty, jako v případě vzdálenosti geodetické, jelikož vektor, který určuje nejkratší vzdálenost v uzlu A , nemusí být vektorem, který určí nejkratší vzdálenost v uzlu pozdějším, a proto je potřeba pro každý uzel uchovávat pole vektorů.

```

1  Vstup: Graf  $G=(u,w,max[])$ , matice zdrojových pixelů
2  S-Výstup: Distanční mapa  $D$ 
3  KMD( $G,S$ ):
4      //Nastavení počátečních hodnot a prázdného listu vektorů pro každý uzel
5       $D[u] := inf$ 
6       $max[u] := NULL$ 
7      //Nastavení hodnot na pozicích zdrojových pixelů
8       $D[s] := 0$ 
9       $max[s] := (0,0,\dots,0)$ 
10
11     Prioritní minimalní fronta  $Q$ 
12      $Q.push(max_s[])$  //Naplnění fronty vektory pro zdrojové pixely
13
14     while  $Q$ -nepřazdna do
15         //Vytáhnutí vektoru s minimálním k-součtem z fronty
16          $minVektor := Q.pop()$ 
17         if  $kSum(minVektor) < D[C]$  do
18              $D[C] := kSum(minVektor)$ 
19
20         for  $N$  in  $sousedniUzly[C]$  do
21             //Přidání nové váhy do vektoru na cestě k-sousednímu pixelu
22              $newVector := minVektor.append(w(N))$ 
23
24
```



```

25      //Nový vektor nepřekrývá jiný vektory v poli vektorů uzlu N
26      if newVektor-neprekryva do
27          maxN[] .append(newVektor)
28          Q.push(newVektor)
29          //Odstranění vektorů překrytých novým vektorem
30          max.odstranPrekryvajici(newVektor)
31          Q.odstranPrekryvajici(newVektor)
32      return D

```

Výpis 2: Algoritmus výpočtu k -max geodetické vzdálenosti

1. V prvním kroku nastavíme počáteční hodnoty vzdáleností výsledné distanční mapy D na nekonečno a zároveň také vyprázdníme všechny pole vektorů každého uzlu u grafu G . U uzlů, které jsou označeny jako zdrojové v S , nastavíme počáteční vzdálenost na 0 a do polí vektorů uzlů $max_s[]$ vložíme vektory $v = (0, 0, \dots, 0)$.
2. Poté vytvoříme minimální prioritní frontu Q a vložíme do ní všechny vektory zdrojových uzlů. Fronta je řazena podle nejnižších hodnot k -vzdáleností vektorů.
3. V cyklu procházíme vytvořenou frontu Q a vytahujeme první vektor této fronty `minVektor` tak dlouho, dokud fronta není prázdná.
4. Pokud je hodnota vzdálenosti distanční mapy $D[C]$, na pozici uzlu C , který ve svém poli vektorů $max_C[]$ obsahuje vektor `minVektor`, vyšší, než požadovaný k -max součet vektoru `minVektor`, uloží se do $D[C] = minVal$.
5. V dalším kroku procházíme sousední uzly N uzlu C a vytvoříme nový vektor `newVektor` obsahující hodnoty vektoru `minVektor` s nově přidanou váhou mezi uzly C a N . Pokud nový vektor `newVektor` nepřekrývá jiný vektor (problematikou překrývání vektorů se podrobněji zabývají autoři v článku [22]), který je již v poli vektorů $max_N[]$ sousedního uzlu N uložen, vložíme tento vektor do fronty Q a také do pole vektorů uzlu N . Po vložení odstraníme z fronty Q a pole vektorů uzlu N , všechny vektory, které byly po vložení nového vektoru `newVektor` překryty.

3.4.3 Minimální bariérová vzdálenost

Pro distanční transformaci s pomocí minimální bariérové vzdálenosti jsme implementovali algoritmus, představen autory v článku [34], který dokáže získat přesné hodnoty MBD v polynomiálním čase.

```

1  Vstup: Graf  $G=(u,w)$ , matice zdrojových pixelů
2  S~Výstup: Distanční mapa D
3  MBD(G,S):
4      //Nastavení počátečních hodnot vzdálenosti na nekonečno
5      D[u] := inf
6      minDt[u] := inf
7      maxDt[u] := inf
8      //Nastavení hodnot na pozicích zdrojových pixelů
9      D[s] := 0
10     minDt[s] := -1
11     maxDt[s] := -1
12
13     Prioritní fronta Q
14     Q.push( $u \in S$ ) //Naplnění fronty zdrojovými pixely
15
16     while Q-neprázdná do
17         C := Q.pop()
18         for N in sousedniUzly[C] do
19             //Minimální a maximální jas v porovnání se sousedním pixelem
20             minVal := min(minDt[C], w(N))
21             maxVal := max(maxDt[C], w(N))
22
23             if (minVal > minDt[N]) then
24                 minDt[N] := minVal
25                 maxDt[N] := maxVal
26                 Q.push(N)
27
28             if ((maxVal - minVal) < D[N]) then
29                 D[N] := maxVal - minVal
30     return D

```

Výpis 3: Algoritmus výpočtu minimální bariérové vzdálenosti

Tento algoritmus při výpočtu využívá prioritní frontu Q , která je seřazena opačně, a to ve smyslu, že místo řazení Q dle hodnot minimálních jasů nalezené cesty tuto frontu řadíme dle maximálních hodnot jasů této cesty. [34]

1. Vytvoříme dvě matice $minDt$ a $maxDt$ stejné velikosti jako vstupní obraz, které budou uchovávat pro každý vrchol grafu minimální a maximální hodnoty jasů na cestě k tomuto

vrcholu. Těmto pomocným maticím dále nastavíme počáteční hodnoty všech pixelů na nekonečno, kromě pixelů ležících na souřadnicích zdrojových pixelů.


2. Poté všechny zdrojové uzly u , označené v matici S , vložíme do prioritní fronty Q , ze které je v cyklu vytahujeme a procházíme všechny sousední uzly.
3. V dalším kroku získáme hodnoty $minVal$ a $maxVal$, odpovídající minimální a maximální hodnotě jasu z aktuálních hodnot v maticích $minDt[C]$ a $maxDt[C]$ uzlu C a jasem jeho sousedního uzlu N . V případě, že je hodnota $minVal$ větší než současná zaznamenaná hodnota na pozici sousedního pixelu v $minDt[N]$ (zmenšení intervalu hodnot), dojde k uložení nových hodnot na pozici sousedního pixelu N do $minDt[N]$, $maxDt[N]$ a sousední pixel N se vloží do fronty Q .
4. V posledním kroku porovnáme, zda nové hodnoty minimálního a maximálního jasu cesty k sousedního pixelu N mají menší rozsah intervalu než současná výsledná hodnota $D[N]$ a v případě že ano, dojde k výpočtu vzdálenosti z nových hodnot a uložení této vzdálenosti do výsledné distanční mapy D .

3.5 Proces segmentace

Metriky budeme aplikovat na segmentaci obrazu, jelikož díky použitému datasetu s obrazem ideální segmentace (viz ilustrace 7) můžeme vůči ideální segmentaci porovnávat i segmentaci získanou pomocí distančních map. Rozdělení obrazu na segmenty dle distančních map nám umožní jejich následnou analýzu a výpočet přesnosti jednotlivých metrik, viz kapitola 3.6.

Po aplikaci DT na obraz získáme dva výstupní obrazy, kde obraz A odpovídá DT pro zdrojové pixely popředí a obraz B DT pro zdrojové pixely pozadí. Principem použité metody segmentace měřením vzdálenosti je rozdělit obraz na dvě oblasti (pixely popředí a pozadí) v závislosti na hodnotě vzdálenosti daného vrcholu. Mějme tedy výstupní distanční mapy A a B dle použité metriky a pixel (vrchol) $V_{i,j}$ se souřadnicemi i, j . Pro určení oblasti, do které tento vrchol patří, nám tedy stačí zjistit hodnotu vzdálenosti v obrazech A a B na souřadnicích i, j . V případě, že hodnota vzdálenosti vrcholu $V_{i,j}$ v obraze A má nižší hodnotu než hodnota vzdálenosti tohoto vrcholu v obraze B, je tento vrchol přiřazen do oblasti A (popředí). V opačném případě je vrchol přiřazen do oblasti B (pozadí).

Při implementaci jsou tedy procházeny obě distanční mapy A a B současně a dle popsaného principu jsou zapisovány hodnoty do výstupního obrazu segmentace stejné velikosti, kde popředí (požadovaný objekt) reprezentuje hodnota jasu 255 (bílá barva) a pozadí hodnota jasu 0 (černá barva), viz ilustrace 9.



Obrázek 9: Segmentace měřením vzdálenosti z distančních map.

3.6 Výpočet přesnosti segmentace

Po aplikaci procesu distanční transformace a získání výsledné segmentace je důležité určit přesnost této segmentace vzhledem k ideální segmentaci, viz obrázek 7c, pro určení přesnosti použité metriky. Přesnost segmentace je tedy dána správností zařazení pixelů do odpovídajících oblastí. Existuje mnoho různých způsobů pro vyhodnocení výsledné segmentace, přičemž v této práci jsme porovnali metriku pixelové přesnosti [35], Sørensen–Diceuv koeficient [36] a Jaccardův index podobnosti [37].

První a zároveň nejjednodušší metodou vyhodnocení přesnosti segmentace je pixelová přesnost. Pixelová přesnost vyhodnocuje segmentaci jako procentuální počet pixelů obrazu, které jsou přiřazeny do správných oblastí, neboli zda je pixel výsledné segmentace na souřadnicích i, j přiřazen do stejné oblasti jako tentýž pixel ideální segmentace. Problém této metriky spočívá v oblastní nevyváženosti, kde jedna oblast, v našem případě pozadí, odpovídá mnohonásobně větší části obrazu než oblast druhá, v našem případě popředí (objekt). [35]

Jaccardův index podobnosti je nejčastěji využívaná metrika vyhodnocení segmentace a to z důvodu její vysoké efektivity. Mějme tedy segmentaci A a ideální segmentaci B požadovaného objektu. Přesnost segmentace je dána jako

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|}, \quad (10)$$

kde $|A \cap B|$ představuje průnik pixelů přiřazených do oblasti objektu a $|A \cup B|$ sjednocení všech pixelů, které byly přiřazeny do oblasti objektu z obou obrazů. [36]


Sørensen–Diceuv koeficient je metrika, která je velmi podobná Jaccardovu indexu podobnosti v tom smyslu, že jsou vzájemně pozitivně korelativní. Pokud jedna z těchto metrik určí, že segmentace obrazu má vyšší přesnost než jiná segmentace, druhá metrika tyto segmentace vyhodnotí se stejným vztahem. Přesnost segmentace je dána jako

$$D(A, B) = \frac{2|A \cap B|}{|A| + |B|}, \quad (11)$$

kde $|A \cap B|$ představuje průnik pixelů přiřazených do oblasti objektu a $|A| + |B|$ součet počtu pixelů segmentací A a B . [37]

Po výpočtu získáme přesnost segmentace jedné oblasti. V našem případě se segmentace skládají ze dvou oblastí (popředí a pozadí) a z tohoto důvodu je potřeba výpočet přesnosti opakovat pro druhou oblast. Výsledná přesnost segmentace obrazu, složeného ze dvou oblastí, je dána jako průměr přesností obou oblastí. [35]

I přestože všechny tři metriky slouží k určení přesnosti segmentace, jsou jejich výsledky na stejných obrazech často velmi odlišné. Pro příklad výpočtu přesnosti mějme segmentaci obrazu a ideální segmentaci požadovaného objektu v obrazu, viz ilustrace 10.



Obrázek 10: Obrazy pro určení přesnosti segmentace.

Oba obrázky v ilustraci 10 mají stejné rozměry 100x100 pixelů. Obraz 10a znázorňuje segmentaci, kterou jsme získali z distančních map vstupního obrazu, kde v tomto případě nedošlo k označení žádných pixelů za pixely popředí. Obraz 10b představuje ideální segmentaci objektů vstupního obrazu (v našem případě tři čtverce o celkové ploše 900 pixelů). Pro tyto obrázky vypočteme přesnost segmentace 10a pomocí zmíněných metrik, viz tabulka 1.

Tabulka 1: Chybovost příkladové segmentace 10a.

Pixelová chyba	Jaccardův index	Sørensen–Diceův koeficient
9.00 %	54.50 %	52.36 %

Hodnoty chybovosti segmentace 10a vzhledem k věrnému povrchu 10b, znázorněné v tabulce 1, dosahují poměrně nízké hodnoty i přes to, že segmentace neoznačila žádný objekt. Tato nízká chybovost je dána již dříve zmíněnou problematikou oblastní nevyváženosti. Chybovost udávána pomocí pixelové přesnosti se s tímto problémem vypořádává nejhůře a dosahuje hodnoty pouze 9 %, přičemž při pohledu na segmentaci je zřejmé, že tuto segmentaci nelze označit za správnou. Z tohoto důvodu se pro určení přesnosti/chybovosti segmentace nejčastěji využívají zbylé dvě metriky, které v našem případě dosahují hodnoty chybovosti nad 50 %. Tyto hodnoty poskytují mnohonásobně přesnější vyhodnocení segmentace a to i v případech, kdy je nepoměr oblastí mnohonásobně vyšší.


4 Výsledky testování

V této kapitole jsou představeny výsledky testování jednotlivých metrik na umělých obrazech a datasetu obrazů představenému v kapitole 3.2. Pro testování jsme vytvořili aplikaci, která aplikuje metriku DT na vstupním obraze, provede segmentaci získaných distančních map a vypočítá chybovost vzhledem k ideální segmentaci. K výpočtu chybovosti jsme použili Jaccardův index podobnosti [37], viz kapitola 3.6. Tyto chybovosti jsme poté použili k porovnání jednotlivých metrik na celém datasetu, vybraných skupinách obrazů dle charakteristik a vyhodnotili jsme vhodnosti použití jednotlivých metrik pro určité třídy obrazů.

4.1 Testování metrik na umělých obrazech

Metriky, představené v kapitole 2.2, mají specifické vlastnosti, které ovlivňují přesnost výsledné distanční mapy. Z tohoto důvodu jsme v této podkapitole vytvořili tři různé umělé obrazy, na kterých ilustrujeme výhody a nevýhody použití jednotlivých metrik. Vlastnosti těchto umělých obrazů se mohou také často vyskytnout na reálných obrazech, viz kapitola 4.2.

První umělý obraz, viz obrázek 11a, se zaměřuje na problematiku šumu v obraze, který se v reálných obrazech vyskytuje poměrně často a dokáže výrazně ovlivnit správnost výsledné distanční mapy. Při porovnání jednotlivých metrik na umělém obraze se šumem jsme nejprve aplikovali proces měření vzdáleností pro získání distančních map od zdrojových bodů popředí a pozadí obrazu (body A a B v obrázku 11a) a poté jsme distanční mapy použili pro segmentaci, viz popis v kapitole 3.5. Tento postup jsme zvolili, jelikož při pohledu na samotné distanční mapy není problematika šumu jasně zřetelná a díky segmentaci ji dokážeme zvýraznit. Cílem tohoto porovnání bylo získat segmentaci, která se co nejvíce přibližuje ideální segmentaci, která by pro tento umělý obraz byla rozdělena přesně v polovině na přechodu jasů dvou oblastí. Výsledkem testování na tomto umělém obraze jsou segmentace z distančních map, viz ilustrace 11.




Obrázek 11: Výsledné segmentace po aplikaci metrik na umělém obraze se šumem.

Z výsledných segmentací můžeme pozorovat již dříve zmíněnou problematiku šumu u geodetické vzdálenosti, viz obrázek 11b, jelikož tato metrika dosahuje výrazně nejhorší přesnosti segmentace. Segmentace, při použití rezistivní geodetické vzdálenosti (s parametry $t_c = 0.8$ a $\lambda = 1$ v rovnici 8), viz obrázek 11c, dosáhla podobných výsledků jako metrika geodetická a

vliv šumu se u ní projevil velmi špatnou segmentací. Nejlepších výsledků poté dosahují k -max a minimální bariérová vzdálenost, viz obrázky 11d a 11e, což nám potvrzuje jejich odolnost vůči šumu, která byla již zmíněna při jejich představení v kapitole 2.2. I přestože jsou obě tyto metriky velmi odolné vůči šumu, můžeme pozorovat, že MBD dosahuje trochu lepší segmentace než k -max (segmentace k -max geodetické vzdálenosti obsahuje občasné nerovnosti na přechodu segmentů) a přesnost segmentace metriky MBD byla tedy při tomto testování nejvyšší.

Druhý umělý obraz, viz obrázek 12a, jsme vytvořili pro znázornění problematiky průchodu malými mezerami v hraně. Malá mezera v hraně se v obraze může vyskytnout také vlivem již zmíněného šumu. Umělý obraz obsahuje pomyslnou bariéru, kterou tvoří černá čára, rozdělující ho na dvě poloviny (dva segmenty) s malými průchody. Při aplikaci DT na tento obraz požadujeme, aby při výpočtu vzdáleností pixelů, které se nacházejí za bariérou, brala aplikovaná metrika v úvahu bariéru a po DT chceme získat distanční mapu znázorňující různé vzdálenosti pro dvě oblasti (před a za bariérou). Výsledkem testování metrik na tomto obraze jsou distanční mapy, viz ilustrace 12.

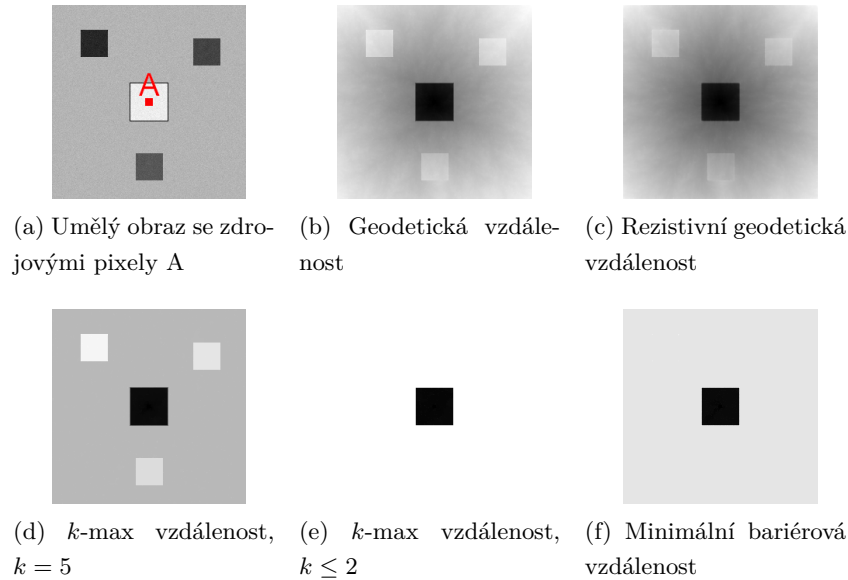


Obrázek 12: Výsledné distanční mapy po aplikaci metrik na umělém obraze s problematikou malé hrany.

Výsledné distanční mapy v ilustraci 12 představují vzdálenosti všech pixelů umělého obrazu od zdrojových pixelů A , kde tmavší barva představuje menší vzdálenosti než barva světlejší. Distanční mapy získané pomocí geodetické, k -max a minimální bariérové vzdálenosti (viz obrázky 12b, 12d a 12e) k určení vzdáleností pixelů za bariérou využily průchody (pixely za bariérou nemají výrazně vyšší vzdálenost než ty před ní) a tudíž je jejich vzdálenost ke zdrojovému bodu A (ležícím v jiném segmentu) velmi podobná, jako vzdálenosti bodů ležících v segmentu před bariérou. Nejlepšího výsledku na tomto umělém obraze dosahuje rezistivní geodetická vzdálenost ($t_c = 1.0$, $\lambda = 25$), viz obrázek 12c, která při výpočtu vzdáleností pixelů za bariérou bere v úvahu malou šířku průchodů (vyšší rezistivita) a pixely za touto bariérou dosahují výrazně vyšší vzdálenosti než pixely před ní.

Třetí umělý obraz, viz obrázek 13a, slouží k znázornění problematiky konstantní vzdálenosti. Tento problém nastává v případě, že při určování vzdálenosti nalezneme hodnoty minimálního a maximálního jasu na počátku cesty k ostatním pixelům, a proto všechny pixely za těmito hodnotami budou mít stejnou vzdálenost od zdrojových pixelů. Umělý obraz tuto problematiku znázorňuje uzavřením zdrojových pixelů A do čtverce, kde pixely uvnitř mají nejvyšší hodnoty

jasu v celém obrazu a samotná hrana tohoto čtverce má hodnotu jasu naopak nejvyšší. Cílem aplikace metrik DT na tento umělý obraz je získat distanční mapu, která určí vhodné vzdálenosti i mimo tento uzavřený čtverec a po vizualizaci uvidíme i tři čtverce, které se nachází v okolí uzavřeného čtverce se zdrojovými pixely. Výsledkem testování metrik na tomto obraze jsou distanční mapy, viz ilustrace 13.



Obrázek 13: Výsledné distanční mapy po aplikaci metrik na umělém obraze s problematikou konstantní vzdálenosti.

Z výsledných distančních map v ilustraci 13 je zřejmé, že u geodetické a rezistivní vzdálenosti došlo k výpočtu správných distančních map (viz obrázky 13b a 13c) a všechny objekty, které se v umělém obraze nachází, jsou na těchto mapách zobrazeny. Zároveň u těchto dvou distančních map můžeme pozorovat výrazný výskyt šumu v oblasti kolem středového čtverce. U distanční mapy získané pomocí MBD (viz obrázek 13f) můžeme pozorovat, že tato metrika našla minimum a maximum intervalu, ze kterého poté získáme vzdálenost (viz kapitola 2.2.4), v rámci čtverce, který ohraničuje zdrojové pixely, a proto všechny hodnoty za hranici jeho hrany mají konstantní vzdálenost a při vizualizaci nedojde k zobrazení ostatních objektů v umělém obraze. K -max geodetická vzdálenost se při nevhodné volbě hodnoty parametru k potýká s obdobným problémem jako MBD, a to ve smyslu, že bere v úvahu k maximálních hodnot na cestě, viz kapitola 2.2.2. Hrana čtverce ohraničující zdrojové pixely má šířku 2 pixely, a proto u této metricky hraje roli správná volba parametru k , kde při $k \leq 2$ nastane stejný problém jako u MBD a ostatní čtverce obrazu nebudou na distanční mapě znázorněny, viz obrázek 13e.

4.2 Testování metrik na reálných obrazech

Pro testování metrik na reálných obrazech z datasetu, viz kapitola 3.2, jsme využili již zmíněnou vytvořenou aplikaci pro získání chybovostí k porovnávání. Z důvodu velkého počtu obrazů jsou u výsledků vždy uvedeny ukázky na vybraných obrazech, které patří do testované skupiny a v případě metrik s parametry (k -max a rezistivní geodetická vzdálenost) jsou vybrány výsledky s parametry, které dosáhly nejpřesnější segmentace. Ilustrace také obsahují distanční mapy popředí, případně pozadí, v závislosti na tom, zda je testovaná problematika na této distanční mapě lépe viditelná.

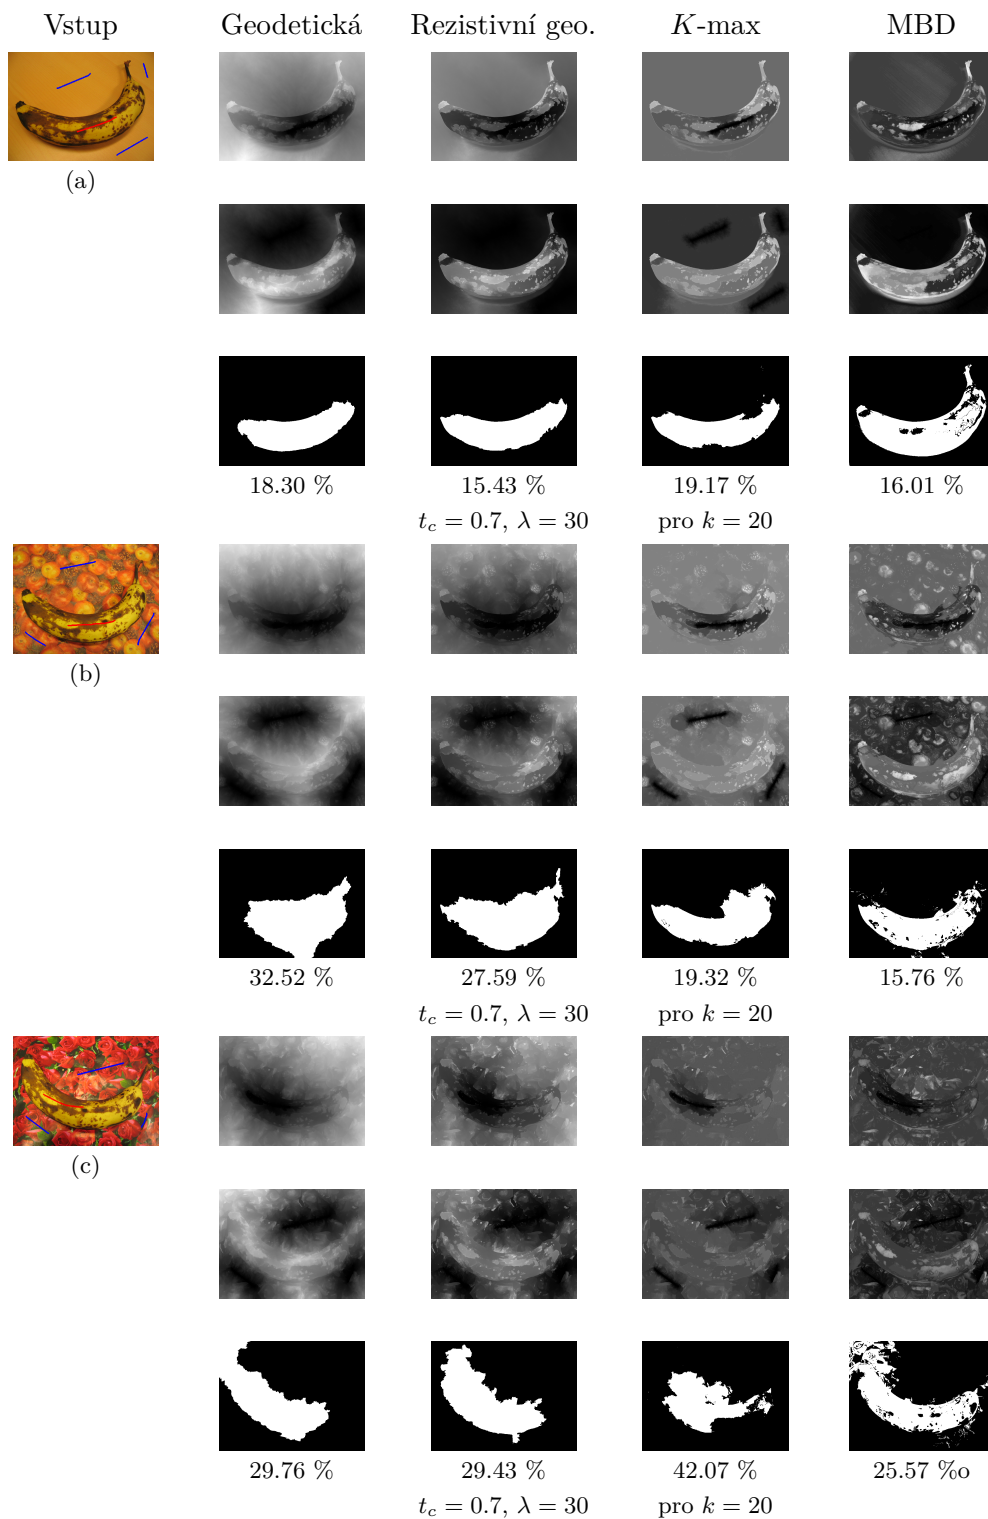
Testování jsme nejprve provedli na celém datasetu obrazů (151 obrazů), z čehož jsme získali chybovosti každého obrazu pro každou vzdálenost. Z chybovosti každého obrazu jsme poté pro každou metriku vypočítali průměrnou chybovost na celém datasetu, viz tabulka 2.

Tabulka 2: Průměrná chybovost metrik na celém datasetu.

Geodetická	Rezistivní geodetická	k-max	MBD
29.04 %	21.78 %	28.38 %	28.49 %

Nejlepší hodnoty chybovosti na celém datasetu dosáhla rezistivní geodetická vzdálenost s průměrnou chybovostí 21.78%. Tento průměr byl vypočítán z nejnižších chybovostí všech parametrů t_c a λ , kde k nejlepší průměrné chybovosti 26.71 % došlo při použití parametrů $t_c = 0.8$ a $\lambda = 8.0$. Tento způsob výpočtu byl poté použit také pro určení průměrné chybovosti k -max geodetické vzdálenosti, kde výsledný průměr byl vypočten z nejnižších chybovostí všech parametrů k , přičemž nejnižší průměrné chybovosti 32.57 % tato metrika dosáhla při použití hodnoty $k = 20$ a nejvyšší průměrné chybovosti 37.59 % při hodnotě $k = 1$. Metriky geodetické, minimální bariérové a k -max geodetické vzdálenosti dosáhly chybovostí horších přibližně o 7 % než při použití rezistivní geodetické vzdálenosti, ovšem jejich průměrné chybovosti segmentací se vzájemně odlišovaly přibližně o 0.5 %. Nejhorší průměrné chybovosti segmentací při tomto testu dosáhla geodetická vzdálenost s hodnotou 29.04 %. Nejlepších výsledků na tomto datasetu, který obsahoval neseskupené obrazy s náhodnými vlastnostmi (jako je například šum, jas, kontrast apod.), jsme tedy dosáhli při použití rezistivní geodetické vzdálenosti pro distanční transformaci obrazu. I přes to, že je průměrná chybovost ostatních metrik velmi podobná, bylo již při prvním testování zřejmé, že jejich chybovosti na stejných obrazech byly velmi odlišné a k podobně přesným segmentacím na stejném obraze docházelo velmi zřídka, což nám dokazuje i jejich odlišné vlastnosti. Pro určení výhodnosti použití jednotlivých metrik je tedy potřeba se zaměřit na vliv těchto vlastností na správnost DT a kategorizovat vhodné charakteristiky obrazů pro jednotlivé metriky, což je předmětem našeho dalšího testování v této kapitole.

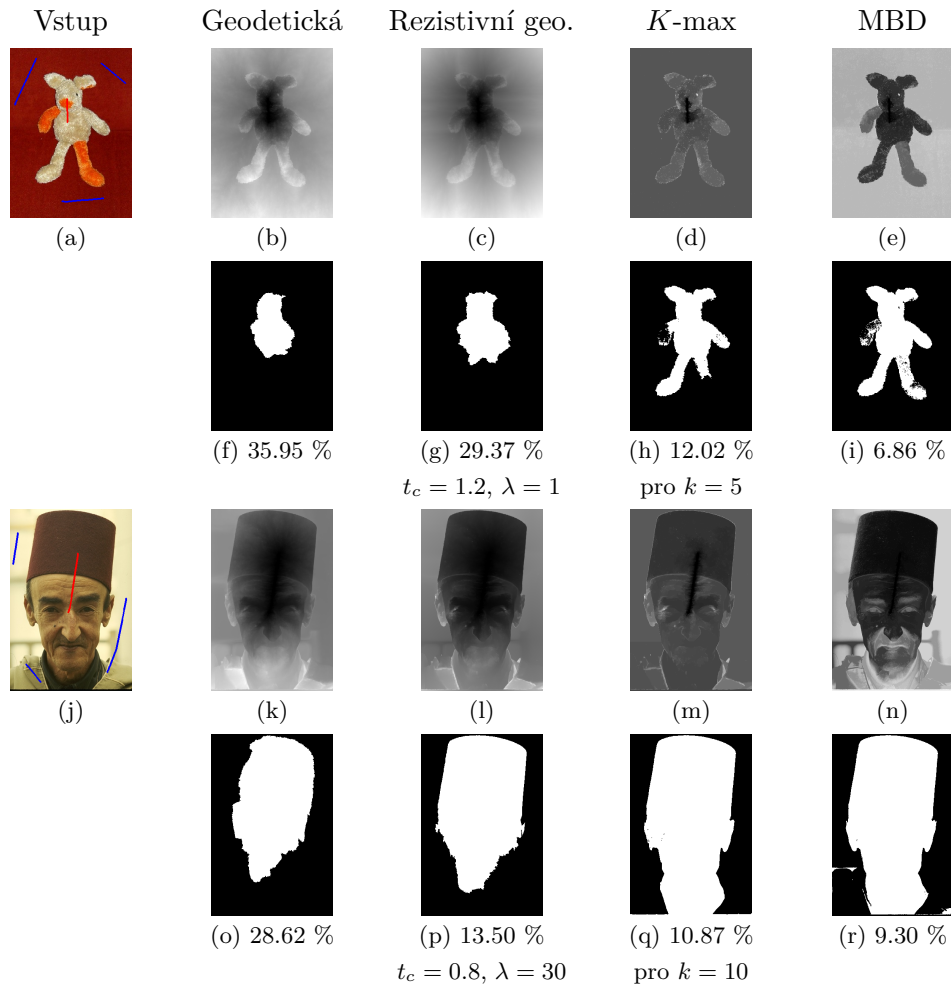
Při následujícím testování jsme se zaměřili na vliv pozadí obrazu na DT a následnou segmentaci. K tomuto účelu jsme využili tři obrazy datasetu, které obsahují stejný objekt na různém pozadí, viz ilustrace 14.



Obrázek 14: Obrazy (a), (b) a (c) jsou vstupní obrazy se zhoršujícím se kontrastem pozadí včetně zdrojových pixelů. Ilustrace také obsahuje výsledné distanční mapy zdrojových pixelů popředí (první řádek vstupního obrazu), pozadí (druhý řádek vstupního obrazu) a segmentace včetně chybovostí (třetí řádek vstupního obrazu) pro každou metriku.

Při vizuální analýze výsledků testování na obrazech se zhoršujícím se kontrastem pozadí můžeme pozorovat, že distanční mapy popředí obrazu 14a, dosáhly poměrně přesných výsledků u všech metrik. Viditelné slabiny distančních map prvního obrazu jsou pouze při aplikaci geodetické vzdálenosti, která nedokázala určit vzdálenosti přechodu objektu na pozadí s takovou přesností jako ostatní a k -max geodetické vzdálenosti, u které došlo k nárůstu některých vzdáleností v rámci objektu (světlejší místa distanční mapy), což je zapříčiněno výskytem tmavých a světlých přechodů v rámci objektu. Z distančních map obrazu 14b je patrné, že u geodetické a rezistivní geodetické vzdálenosti došlo k výraznému zhoršení DT a tyto metriky již nedokázaly rozpoznat hranici objektu a došlo k jeho částečnému splynutí s pozadím (distanční mapy již neobsahují ostrý přechod mezi oblastmi). U ostatních metrik došlo k mírnému zhoršení viditelnosti rysů objektu. Při analýze distančních map obrazu 14c s nejhorším kontrastem pozadí bylo použití geodetické a rezistivní geodetické vzdálenosti ovlivněno šumem již natolik, že v jejich distančních mapách došlo k velmi velkému splynutí objektu s pozadím a jeho rysy jsou téměř nerozpoznatelné. Velkým problémem se tento obraz stal také pro k -max geodetickou vzdálenost, u které nedošlo ke splynutí pouze hran objektu, ale téměř celého jeho povrchu, čímž následná segmentace dosáhla nejvyšší chybovosti 41.40 %. U MBD došlo k zhoršení rozpoznatelnosti distanční mapy, ovšem v porovnání s ostatními metrikami její výsledek můžeme považovat za velmi dobrý. Po analýze výsledků můžeme určit, že zhoršení kontrastu pozadí mělo nejmenší vliv při použití minimální bariérové vzdálenosti pro DT obrazu. Geodetická a rezistivní geodetická vzdálenost byla ovlivněna kontrastem pozadí nejvíce a jejich segmentace se výrazně zhoršily i při mírném zhoršení kontrastu. K -max geodetická vzdálenost dosáhla poměrně dobrých segmentací při mírně zhoršeném kontrastu pozadí, ovšem poté již její chybovost velmi rostla a na obraze s nejhorším kontrastem pozadí dosáhla nejhorší segmentace, což bylo způsobeno tím, že hrany, které se vyskytovaly v pozadí, byly výraznější než hrany mezi objektem a jeho pozadím.

Při dalším testování jsme se zaměřili na vliv obrazového šumu na přesnost výsledných distančních map. V reálných obrazech se problematika šumu, se kterou se potýká geodetická vzdálenost, vyskytovala poměrně často a pro její testování jsme vybrali dva obrazy, viz ilustrace 15.




Obrázek 15: Obrazy pro testování vlivu šumu v reálných obrazech. Obrázky (a) a (j) jsou vstupní obrazy se zdrojovými pixely. Ilustrace také obsahuje výsledné distanční mapy zdrojových pixelů popředí a segmentace včetně chybovostí pro každou metriku.

Obrázek 15a obsahuje velké množství šumu ve formě malých rozdílů jasu v rámci jeho plochy. Při pohledu na výsledné distanční mapy popředí tohoto obrazu, jsou ihned viditelné velmi špatné výsledky geodetické a rezistivní geodetické vzdálenosti, viz obrázky 15b a 15c, u kterých dochází z důvodu výskytu šumu k velmi rychlému nárůstu vzdáleností od zdrojových bodů a u těchto distančních map je zřejmé, že vzdálenosti na konci končetin objektu jsou mnohonásobně vyšší i přes to, že jsou stále součástí požadovaného objektu. Segmentace získané z těchto map jsou mnohonásobně horší než při použití k -max geodetické vzdálenosti nebo MBD. Tyto metriky byly šumem ovlivněny téměř minimálně a při pohledu na jejich distanční mapy je zřejmé, že vzdálenosti bodů v oblasti objektu jsou výrazně nižší a zároveň je také dobře viditelná hranice požadovaného objektu s pozadím. I přes to, že druhý obraz 15j již neobsahuje takové množství šumu, jsou výsledky při použití geodetické a rezistivní geodetické metriky, viz obrázky 15k a 15l, horší než u ostatních metrik a postupným nárůstem vzdáleností (způsobeným šumem) jsou

ovlivněny zejména okraje čepice člověka a spodní část obličeje, což můžeme pozorovat také na výsledných segmentacích těchto metrik. Tímto testováním jsme ověřili, že šum dokáže ovlivnit výsledky DT reálných obrazů a to i přes to, že nemusí být výrazný. Zároveň se také projevila již zmíněná dobrá odolnost vůči šumu u k -max geodetické a minimální bariérové vzdálenosti.

Problematika konstantní vzdálenosti, se kterou se potýká MBD a v některých případech i k -max vzdálenost, se v reálných obrazech nevyskytuje tak často jako šum a je velmi závislá na špatné poloze zdrojových pixelů. Ilustrace 16 obsahuje obrazy pro testování problematiky konstantní vzdálenosti.






















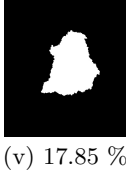
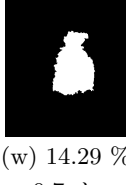
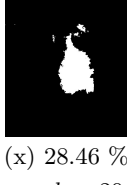
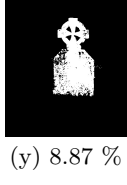
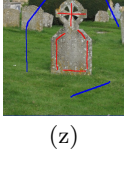
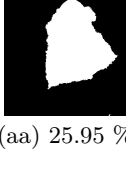
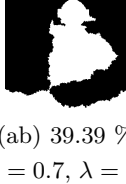
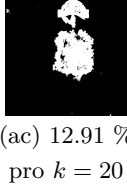
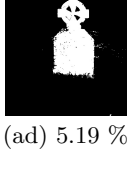


Obrázek 16: Obrazy pro testování problematiky konstantní vzdálenosti v reálných obrazech. Obrázek (a) je vstupní obrazy s původními zdrojovými pixely. Obrázek (j) je vstupní obrazy s upravenými zdrojovými pixely. Ilustrace také obsahuje výsledné distanční mapy zdrojových pixelů popředí a segmentace včetně chybovostí pro každou metriku.

Na ilustraci 16 můžeme pozorovat problematiku konstantní vzdálenosti, která se projevila při použití MBD. Vizuální analýzou výsledků je zřejmé, že MBD, viz obrázek 16e, vypočítala příliš vysoké vzdálenosti u části objektu (nohy postavy mají vyšší vzdálenost ke zdrojovým pi-

xelům popředí než k pozadí) a při segmentaci došlo k nesprávnému přiřazení pixelů do segmentu pozadí, viz obrázek 16i. Problém nastal z důvodu nevhodné pozice zdrojových pixelů objektu, jelikož šaty postavy mají nejnížší hodnotu jasu z celého obrazu a při výpočtu vzdáleností směrem dolů, k nohám postavy, nalezneme ihned hodnotu jasu vyšší (horní hranice intervalu) a při dalším postupu je nejnížší i nejvyšší hodnota jasu v intervalu konstantní. Výsledná velikost vzdáleností noh postavy od zdrojových bodů objektu bude tedy vždy vyšší než jejich vzdálenost od zdrojových pixelů pozadí. Pro vyřešení tohoto problému jsme znázornili změnu pozice zdrojových pixelů pro popředí, viz obrázek 16j. Zdrojové pixely vstupního obrazu 16j přesahují přes spodní hranu šatů a při výpočtu vzdáleností pro nohy postavy bude algoritmus využívat tyto nové zdrojové pixely, které se již nenachází v oblasti s nejnížší hodnotou jasu, díky čemu získáme segmentaci (při aplikaci MBD), která správně označí téměř celou postavu s nižší chybovostí, viz obrázek 16r. Zajímavým zjištěním je také chybovost k -max geodetické vzdálenosti, která při úpravě pozice zdrojových pixelů zůstala konstantní pro $k = 1$ (u ostatních parametrů k došlo k odchylkám v rozmezí 1 %). Tento fakt naznačuje její odolnost vůči malým změnám počtu zdrojových pixelů.

Díky předchozímu testování jsme zjistili, že důležitým faktorem ovlivňujícím výpočet distančních map a následnou segmentaci, je poloha zdrojových bodů. Z tohoto důvodu jsme pro toto testování vybrali dva obrazy, na kterých jsme porovnali výsledky dosažené při rozdílných polohách zdrojových pixelů. Pro výpočet jsme použili zdrojové body z datasetu, menší počet zdrojových bodů a zdrojové body, které jsou rozprostřeny v objektu a více odpovídají jeho obrysu. Ilustrace 17 obsahuje výsledné segmentace vstupních obrazů s různými zdrojovými body.

Vstup	Geodetická	Rezistivní geo.	K -max	MBD
				
(a)	(b) 41.29 %	(c) 30.18 % $t_c = 0.9, \lambda = 2$	(d) 35.89 % pro $k = 5$	(e) 25.27 %
				
(f)	(g) 32.8 %	(h) 16.94 % $t_c = 0.9, \lambda = 2$	(i) 21.54 % pro $k = 5$	(j) 25.68 %
				
(k)	(l) 6.80 %	(m) 18.25 % $t_c = 0.9, \lambda = 2$	(n) 3.84 % pro $k = 5$	(o) 3.57 %
				
(p)	(q) 37.60 %	(r) 27.66 % $t_c = 0.7, \lambda = 20$	(s) 25.27 % pro $k = 20$	(t) 15.47 %
				
(u)	(v) 17.85 %	(w) 14.29 % $t_c = 0.7, \lambda = 20$	(x) 28.46 % pro $k = 20$	(y) 8.87 %
				
(z)	(aa) 25.95 %	(ab) 39.39 % $t_c = 0.7, \lambda = 20$	(ac) 12.91 % pro $k = 20$	(ad) 5.19 %

Obrázek 17: Obrázky pro testování vlivu pozice zdrojových pixelů na DT. Obrázky (f) a (u) jsou vstupní obrázky, u kterých byly použity původní zdrojové pixely z datasetu. U obrázků (a), (k), (p) a (z) byly použity vlastní zdrojové pixely. Ilustrace také obsahuje výsledné segmentace vzdálenostních map a jejich chybovosti pro každou metriku.

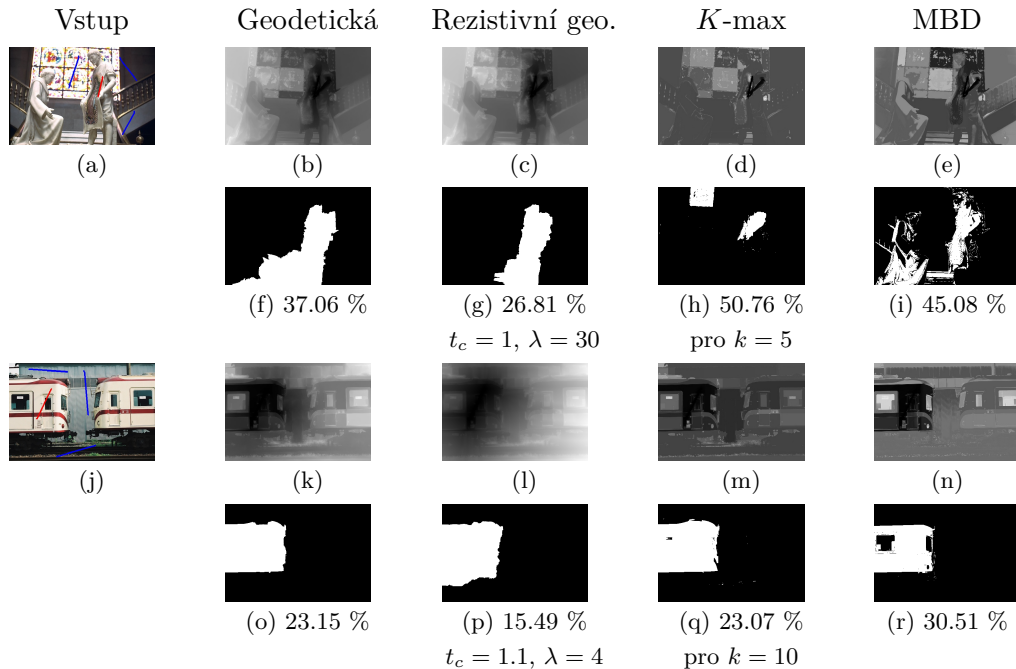
Z výsledných segmentací můžeme pozorovat, že při použití geodetické a rezistivní geodetické vzdálenosti jsou segmentace obrazů s menším počtem zdrojových bodů, viz obrázky 17a a 17p, velmi nepřesné a neodpovídají požadovanému objektu. Při vyšším počtu zdrojových bodů došlo k zlepšení segmentací, ovšem zároveň u zdrojových bodů odpovídajících obrysu, viz obrázky 17z a 17k, došlo k navýšení chybného přiřazení pixelů v blízkém okolí objektu, viditelné zejména na segmentacích 17aa a 17m, což může způsobit, že chybovost výsledné segmentace bude vyšší než při méně přesných pozicích zdrojových pixelů. Segmentace s použitím k -max geodetické vzdálenosti byla přesnější pozicí zdrojových pixelů ovlivněna nejvíce. U této metriky došlo k výraznému zlepšení přesnosti segmentací distančních map s vyšším počtem zdrojových pixelů a při vizuální analýze byl požadovaný objekt více rozpoznatelný. Zároveň můžeme pozorovat její již zmíněnou odolnost vůči malé změně počtu zdrojových pixelů při jejich ponechání ve stejné oblasti obrazu, viz segmentace 17s a 17x. Metrika MBD dosáhla nejpresnějších segmentací a to jak v případě použití původních zdrojových pixelů, tak i při použití upravených zdrojových pixelů. Zároveň můžeme pozorovat, že i v případě, kdy byly použity menší počty zdrojových pixelů, tak segmentace této metriky byla velmi přesná a objekt byl dobře rozpoznatelný.

Z výsledků testování na těchto obrazech se metrikou, která při vyšším počtu zdrojových pixelů dosáhla v obou případech vyšší přesnosti, jednoznačně stala k -max geodetická vzdálenost. U geodetické a rezistivní geodetické vzdálenosti se přesnější pozice zdrojových bodů neprojevila přesnější segmentací, ale spíše označením větší oblasti za objekt a to bez ohledu na jeho přechod s pozadím. Tento fakt značí, že přesnost jejich segmentací, je spíše ovlivněna ostatními charakteristikami obrazu (šum, jas a kontrast) než samotnou pozicí zdrojových pixelů. Zajímavým zjištěním je ovšem vliv pozice zdrojových pixelů pozadí v případě, že se v objektu nachází díry nebo průniky pozadí do oblasti objektu, jelikož pokud se zdrojové body pozadí nenachází také v těchto kritických oblastech (díry na náhrobním kameni a ucho vázy), dojde k nesprávnému určení vzdáleností a tyto oblasti byly v našem případě nesprávně přiřazeny do segmentu popředí, viz segmentace 17aa a 17ab. MBD dosáhla přesných segmentací, na kterých se při vizuální analýze dá objekt velmi dobře rozpoznat, bez ohledu na pozici zdrojových pixelů, což nám značí její vysokou odolnost vůči jejich přesné poloze v rámci objektu.

Poslední oblastí našeho testování bylo určení charakteristik obrazu, na kterých jednotlivé metriky dosáhnou nejpresnější DT vzhledem k ostatním metrikám. Pro tento účel jsme brali v úvahu celý dataset obrazů, ze kterého jsme pro každou metriku vybrali malou skupinu obrazů, u kterých byla přesnost segmentace dané metriky výrazně vyšší než při aplikaci ostatních metrik.

Při tomto testování dosáhla geodetická vzdálenost nejlepšího výsledku pouze na jednom obraze z celého datasetu, na kterém měla rezistivní geodetická vzdálenost přesnost horší pouze o 2 %. Tento fakt je způsoben tím, že ostatní vzdálenosti vznikly jako reakce na nedostatky právě geodetické vzdálenosti, a proto při našem testování dosáhla geodetická vzdálenost většinou horších výsledků. Nejvýraznější vlastnosti ovlivňující DT geodetické metriky byly předmětem předchozího testování (šum, kontrast pozadí a pozice zdrojových bodů), tudíž jsme se při tomto testování zaměřili zejména na porovnávání vhodných charakteristik obrazu pro ostatní metriky.

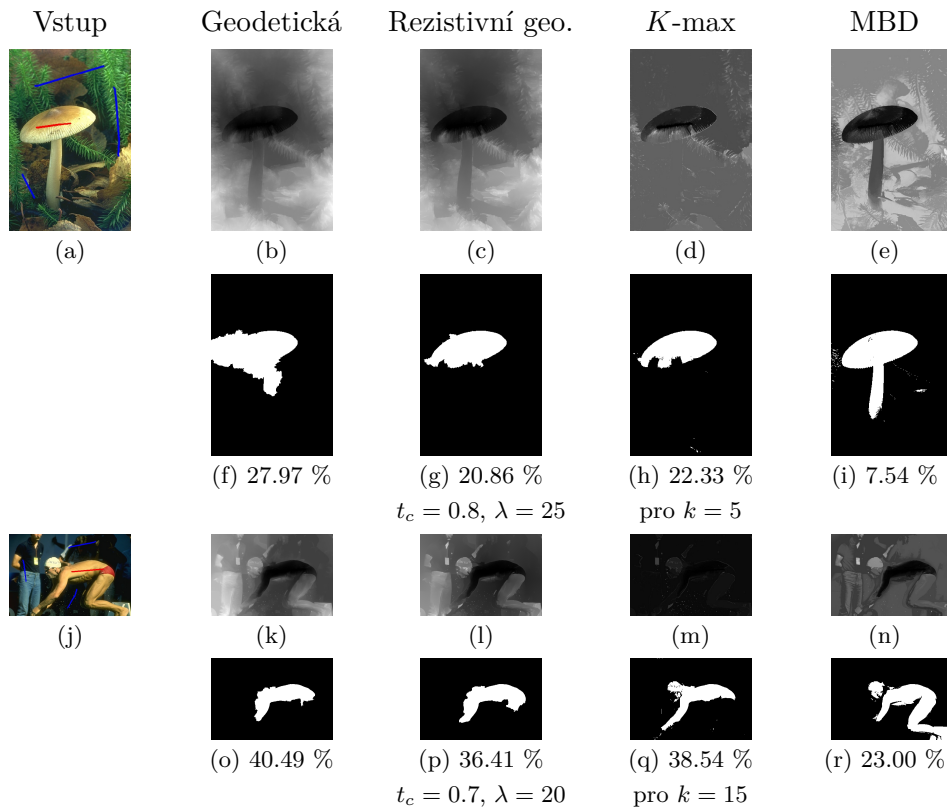
Rezistivní geodetická vzdálenost dosáhla nejpřesnějších segmentací celkem na 94 obrazech z datasetu, přičemž při této analýze jsme vybrali dva, na kterých byla její přesnost vůči ostatním nejvýraznější, viz ilustrace 18.



Obrázek 18: Obrazy, na kterých bylo nejvýhodnější využití rezistivní geodetické vzdálenosti. Obrázky (a) a (j) jsou vstupní obrazy se zdrojovými pixely. Ilustrace také obsahuje výsledné distanční mapy zdrojových pixelů popředí a segmentace včetně chybovostí pro každou metriku.

Obrázek 18a obsahuje objekt, u kterého dochází k přechodu do jeho pozadí bez výrazné změny jasu nebo kontrastu a objekt v některých částech s pozadím téměř splývá. U rezistivní geodetické vzdálenosti dokážeme díky volbě parametrů t_c a λ ovlivnit její citlivost na výskyt malých průchodů v hranách a díky tomu došlo k zlepšení výpočtu vzdáleností v oblasti kolem objektu (viditelné zejména na dlaždicích okna), kde se při přechodu vyskytovaly malé průchody v hranách, díky kterým vznikl nárůst vzdáleností v této části pozadí. Obdobný jev můžeme pozorovat také ve spodní části pozadí, kde se malé průchody vyskytly z důvodu obrazového šumu a ve výsledné segmentaci 18g se zmenšila oblast přiřazená do pozadí oproti segmentaci geodetické vzdálenosti, viz obrázek 18f. Obrázek 18j zobrazuje objekt, který se skládá z částí s různým jasnem a ideální segmentace obsahuje obě tyto části (bílou část vagónu včetně jeho černého podvozku). Díky parametrům rezistivní vzdálenosti můžeme pozorovat, že distanční mapa 18l a segmentace 18p neobsahuje ostrý přechod velikostí vzdáleností při posunu směrem k podvozku, ale v této části došlo k postupnému nárůstu, díky čemuž byla i tato část objektu při segmentaci správně přiřazená. Tato metrika tedy při našem testování dosáhla větší přesnosti segmentací při výskytu malých průchodů na přechodu splývajícího objektu s pozadím a díky možnosti volby citlivosti na přechody jasů.

Minimální bariérová vzdálenost dosáhla nejpresnějších segmentací celkově na 32 obrazech z datasetu, ze kterých jsme vybrali dva pro analýzu jejich charakteristik, viz ilustrace 19.

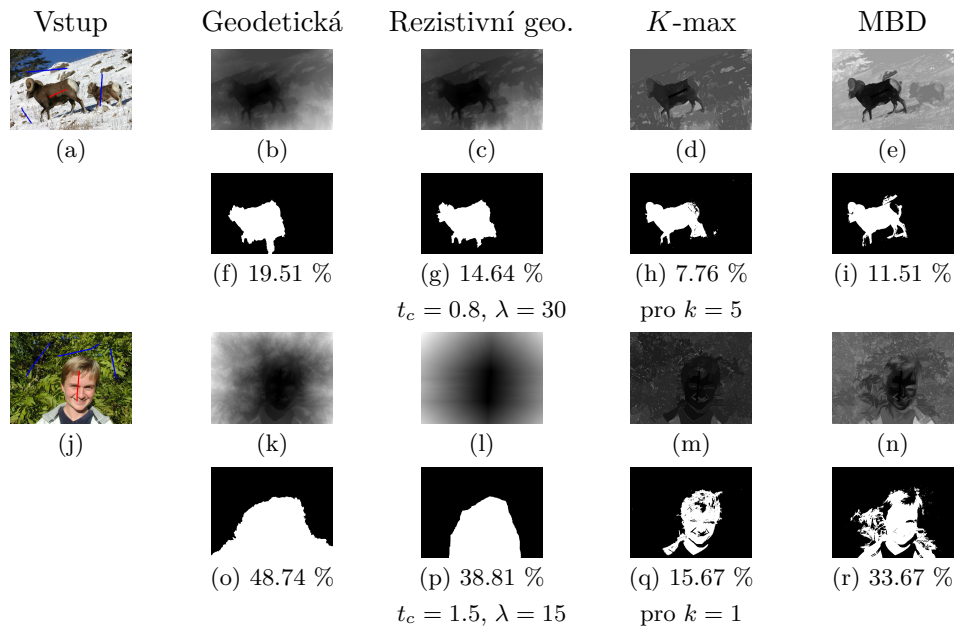


Obrázek 19: Obrazy, na kterých bylo nejvýhodnější využití MBD. Obrázky (a) a (j) jsou vstupní obrazy se zdrojovými pixely. Ilustrace také obsahuje výsledné distanční mapy zdrojových pixelů popředí a segmentace včetně chybovostí pro každou metriku.

Při pohledu na distanční mapu 19e získanou pomocí MBD je viditelné, že tato metrika si poradila s drobnými nečistotami hodnot jasu objektu bez problému (klobouk hříbu) a zároveň jako jediná vypočítala vhodné vzdálenosti pro třen hříbu, které při segmentaci vedly k jeho korektnímu přiřazení do segmentu objektu. Obraz 19j zobrazuje objekt, který má výrazný kontrast vůči jeho pozadí. Distanční mapa získaná s pomocí MBD, viz obrázek 19r, reprezentuje požadovaný objekt poměrně přesně a při vizuální analýze jsou velmi dobře rozděleny jednotlivé hrany, na kterých dochází k přechodu objektu a pozadí, z čehož můžeme pozorovat její výborné schopnosti rozpoznání přechodů jasů k určení hrany objektu. Při našem testování se MBD prokázala jako vhodnější metrika pro DT obrazů, jejichž objekt měl zřetelný přechod s pozadím a dobrý kontrast, ovšem v závislosti na vhodně zvolené pozici zdrojových pixelů, které přesahují i přes barevné přechody pro zabránění výskytu problematiky konstantní vzdálenosti.

K -max geodetické vzdálenosti dosáhla nejpresnějších segmentací celkově na 25 obrazech z datasetu. Při analýza charakteristik obrazů, na kterých je využití této metriky nejvýhodnější, jsme

vybrali dva obrazy pro různé hodnoty parametru k , jejichž přesnost segmentace byla oproti ostatním metrikám vyšší, viz ilustrace 20.



Obrázek 20: Obrazy, na kterých bylo nejvýhodnější využití k -max geodetické vzdálenosti pro různé hodnoty parametru k . Obrázky (a) a (j) jsou vstupní obrazy se zdrojovými pixely. Ilustrace také obsahuje výsledné distanční mapy zdrojových pixelů popředí a segmentace včetně chybovosti pro každou metriku.

Při vizuální analýze distančních map k -max geodetické a minimální bariérové vzdálenosti je zřejmé, že jejich vzhled je velmi podobný. Předností k -max geodetické vzdálenosti je ovšem její parametr k , díky kterému můžeme vzít v úvahu větší počet nejvyšších hran na cestě k danému bodu a tím vyřešit již zmíněnou problematiku konstantní vzdálenosti. Využití této vlastnosti můžeme pozorovat na distančních mapách 20d a 20e, kde distanční mapa 20e při použití MBD určila příliš nízké vzdálenosti části pozadí (kámen za zvířetem), ovšem tento problém byl v distanční mapě 20d vyřešen zvýšením hodnoty k (chybovost při hodnotě $k = 1$ byla 14.15 %). Při pohledu na distanční mapu 20m je patrná její vysoká odolnost vůči obrazovému šumu (šum se na tomto obraze vyskytuje především v pozadí) při nižší hodnotě parametru k (chybovost s parametrem $k = 20$ byla 48.99 %). Výhodnost použití k -max geodetické vzdálenosti při našem testování byla díky její schopnosti dobré detekce přechodu mezi jasy patrná zejména na obrazech s dobrým kontrastem objektu vůči pozadí a při výskytu obrazového šumu. Díky její hodnotě k dokázala dosáhnout lepších výsledků na obrazech, u kterých se z důvodu nevhodné pozice zdrojových pixelů vyskytovala problematika konstantní vzdálenosti při použití metody MBD. Důležité je ovšem zmínit její velmi špatnou přesnost při DT obrazů s nevýrazným objektem, slabým kontrastem a výskytem nečistot v oblasti objektu, kterou jsme ověřili při předchozím testování.

Závěr

Cílem této bakalářské práce bylo seznámit se s existujícími vzdálenostmi, které se používají v analýze obrazu, otestovat vybrané vzdálenosti na různých obrazech, z dosažených výsledků vytvořit porovnání jednotlivých metrik a určit vhodnost jejich použití. Pro vytvoření aplikace, která převede vstupní obraz na distanční mapu dle zdrojových pixelů, provede segmentaci měřením vzdálenosti pro porovnání s ideální segmentací obrazu a vypočte přesnosti dosažené segmentace, jsme zvolili programovací jazyk C++ a knihovnu OpenCV.

Při našem testování se nejpřesnější metrikou na reálných obrazech z datasetu bez seskupení (jas, šum, kontrast apod.) stala rezistivní geodetická vzdálenost s přesností segmentace vyšší až o 7 % než při použití ostatních metrik. Dále jsme se zaměřili na vliv pozadí tří různých obrazů, na kterých metrika MBD dosáhla nejvyšší odolnosti vůči zhoršenému kontrastu pozadí. K -max geodetická vzdálenost dosáhla poměrně dobrých výsledků při mírném zhoršení kontrastu pozadí, ovšem při dalším zhoršení již nebyla při našem testování pro použití vhodná. Ověřením výskytu problematik na reálných obrazech jsme zjistili, že i přes to, že šum nemusí být výrazný, jsou jím geodetická a rezistivní geodetická vzdálenost velmi ovlivněny a jejich použitím na obrazech se šumem jsme získali nepřesné výsledky. Prokázala se nám také vysoká odolnost vůči šumu k -max geodetické a minimální bariérové vzdálenosti, které dosahovaly vyšších přesností až o 15 %. Při testování problematiky konstantní vzdálenosti nám vyšlo najevo, že poloha zdrojových pixelů hraje velkou roli ve výsledné přesnosti a proto jsme provedli také testování vlivu jejich pozic, ve kterém dosáhla k -max geodetická vzdálenost výrazně vyšší přesnosti při lepším pokrytí objektu zdrojovými pixely. MBD nám prokázala její odolnost vůči tomu, zda zdrojové pixely pokrývají celou oblast objektu, avšak s ohledem na jejich správnou pozici pro prevenci výskytu konstantní vzdálenosti.

Poslední oblastí našeho testování bylo nalezení vhodných charakteristik obrazu pro jednotlivé metriky. Z výsledků tohoto testování jsme vyzorovali, že geodetická vzdálenost je velmi podobná rezistivní geodetické vzdálenosti a při testování byla zastíněna lepšími výsledky právě této metriky. Rezistivní geodetická vzdálenost dosáhla přesnějších výsledků na obrazech s objekty, které měly nevýrazný přechod jasů s pozadím a díky volbě hodnot parametrů t_c a λ jsme dokázali ovlivnit její citlivost na tento přechod jasů s případným využitím nárůstu vzdálenosti při průchodu malými mezerami v hranách na přechodu objektu s pozadím. Při testování MBD vyšlo najevo, že tato metrika dosáhla výrazně lepších výsledků na obrazech s dobrou viditelností hran objektu a dobrým kontrastem. K -max geodetická vzdálenost při testování prokázala dobré výsledky na obrazech s dobrým kontrastem a díky možnosti ovlivnění problematiky konstantní vzdálenosti správnou volbou parametru k dokázala v některých případech dosáhnout také lepších výsledků než metrika MBD.

Tato práce může být z pohledu dalšího vývoje tématu rozšířena o aplikaci a porovnání nově vyvinutých metrik v oblasti měření vzdáleností v obraze.

Seznam literatury

1. *Image Analysis and Computer Vision* [online]. NC State University, 2016 [cit. 2020-02-10]. Dostupné z: <https://www.ece.ncsu.edu/research-area/csp/iacv/>.
2. *What is a digital Image?* [online]. Sheets [cit. 2020-01-24]. Dostupné z: <https://sites.google.com/site/learnimagej/image-processing/what-is-a-digital-image>.
3. MENDOZA, Fernando; LU, Renfu. Basics of Image Analysis. In: 2015-01, s. 9–56. Dostupné z DOI: 10.1007/978-1-4939-2836-1_2.
4. WIKIPEDIA CONTRIBUTORS. *Image analysis* — *Wikipedia, The Free Encyclopedia*. 2020. Dostupné také z: https://en.wikipedia.org/w/index.php?title=Image_analysis&oldid=935090940 [Online; cit. 2020-2-11].
5. *Image Analysis and Computer Vision* [online]. NC State University, c2016 [cit. 2020-02-10]. Dostupné z: <https://www.ece.ncsu.edu/research-area/csp/iacv/>.
6. KHAN, Am; SRISHA, Ravi. Image Segmentation Methods: A Comparative Study. *International Journal of Soft Computing and Engineering*. 2013-09, s. 2231–2307.
7. FERRARI, Stefano. *Image segmentation Segmentation by thresholding* [online]. Università degli Studi di Milano: Ferrari, 2018 [cit. 2020-02-20]. Dostupné z: https://homes.di.unimi.it/ferrari/MethImageProc2018_19/MIP2018_19_16_segmentation_double.pdf.
8. ADAMS, R.; BISCHOF, L. Seeded region growing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1994, roč. 16, č. 6, s. 641–647.
9. *Understanding U-Net Architecture For Image Segmentation* [online]. Cere Labs, 2018 [cit. 2020-04-02]. Dostupné z: <https://medium.com/@CereLabs/understanding-u-net-architecture-for-image-segmentation-74bef8caefee>.
10. PROTIERE, Alexis; SAPIRO, Guillermo. Interactive image segmentation via adaptive weighted distances. *IEEE Transactions on Image Processing*. 2007, s. 1046–1057.
11. BONNET, N; CUTRONA, J; HERBIN, M. A ‘no-threshold’ histogram-based image segmentation method. *Pattern Recognition*. 2002, roč. 35, č. 10, s. 2319–2322. ISSN 0031-3203. Dostupné z DOI: [https://doi.org/10.1016/S0031-3203\(02\)00057-2](https://doi.org/10.1016/S0031-3203(02)00057-2).
12. KENNEY, Jacqueline; BUCKLEY, Thomas; BROCK, Oliver. Interactive segmentation for manipulation in unstructured environments. In: *2009 IEEE International Conference on Robotics and Automation*. 2009, s. 1377–1382.
13. SATHYA, B.; MANAVALAN, R. Image Segmentation by Clustering Methods: Performance Analysis. *International Journal of Computer Applications*. 2011-09, roč. 29, s. 27–32. Dostupné z DOI: 10.5120/3688-5127.

14. ZHAO, Hengshuang; QI, Xiaojuan; SHEN, Xiaoyong; SHI, Jianping; JIA, Jiaya. Icnnet for real-time semantic segmentation on high-resolution images. In: *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018, s. 405–420.
15. PEDDIREDDY, Rama Prasada Reddy; SEMWAL, Sudhanshu Kumar. Implementation of Distance Transformation in the Processing Language.
16. BORGEFORS, Gunilla. Distance transformations in digital images. *Computer vision, graphics, and image processing*. 1986, roč. 34, č. 3, s. 344–371. Dostupné také z: http://www.cmm.mines-paristech.fr/~marcoteg/cv/publi_pdf/MM_refs/1986_Borgefors_distance.pdf.
17. BLACK, Paul E. "Manhattan distance": in *Dictionary of Algorithms and Data Structures* [online]. Ed. 11 February 2019. [Cit. 2020-04-22]. Dostupné z: <https://xlinux.nist.gov/dads/HTML/manhattanDistance.html>.
18. DIJKSTRA, E. W. A Note on Two Problems in Connexion with Graphs. *Numer. Math.* 1959-12, roč. 1, č. 1, s. 269–271. ISSN 0029-599X. Dostupné z DOI: 10.1007/BF01386390.
19. STRAND, Robin; CIESIELSKI, Krzysztof Chris; MALMBERG, Filip; SAHA, Punam K. The Minimum Barrier Distance: A Summary of Recent Advances. In: KROPATSCH, Walter G.; ARTNER, Nicole M.; JANUSCH, Ines (ed.). *Discrete Geometry for Computer Imagery*. Cham: Springer International Publishing, 2017, s. 57–68. ISBN 978-3-319-66272-5.
20. WIKIPEDIA CONTRIBUTORS. *Euclidean distance* — *Wikipedia, The Free Encyclopedia*. 2020. Dostupné také z: https://en.wikipedia.org/w/index.php?title=Euclidean_distance&oldid=946159687. [Online; cit. 2020-4-1].
21. ECONOMOU, G.; POTHOS, V.; IFANTIS, A. Geodesic distance and MST based image segmentation. In: *2004 12th European Signal Processing Conference*. 2004-09, s. 941–944. ISSN null.
22. HOLUŠA, Michael; SOJKA, Eduard. The k-max distance in graphs and images. *Pattern Recognition Letters*. 2017, roč. 98, s. 103–109. ISSN 0167-8655. Dostupné z DOI: <https://doi.org/10.1016/j.patrec.2017.09.003>.
23. YU, Jaehong; KIM, Seoung. Density-Based Geodesic Distance for Identifying the Noisy and Nonlinear Clusters. *Information Sciences*. 2016-04, roč. 360. Dostupné z DOI: 10.1016/j.ins.2016.04.032.
24. GAURA, Jan; SOJKA, Eduard. Resistance-geodesic distance and its use in image segmentation. 2016. ISSN 1793-6349. Dostupné z DOI: 10.1142/S0218213016400029.
25. KLEIN, Douglas; RANDIC, Milan. Resistance Distance. *Journal of Mathematical Chemistry*. 1993-12, roč. 12, s. 81–95. Dostupné z DOI: 10.1007/BF01164627.

26. BABIC, Darko; KLEIN, Douglas; LUKOVITS, I.; NIKOLIĆ, Sonja; TRINAJSTIĆ, N. Resistance-distance matrix: A computational algorithm and its application. Dedicated to the memory of Professor Per-Olov Löwdin (1916–2000). *International Journal of Quantum Chemistry*. 2002-01, roč. 90, s. 166–176. Dostupné z DOI: 10.1002/qua.10057.
27. ZHANG, Jianming; SCLAROFF, Stan; LIN, Zhe; SHEN, Xiaohui; PRICE, Brian; MECH, Radomir. Minimum Barrier Salient Object Detection at 80 FPS. In: *The IEEE International Conference on Computer Vision (ICCV)*. 2015-12.
28. *About OpenCV* [online]. OpenCV team, c2019 [cit. 2020-02-08]. Dostupné z: <https://opencv.org/about/>.
29. GULSHAN, Varun; ROTHER, Carsten; CRIMINISI, Antonio; BLAKE, Andrew; ZISSERMAN, Andrew. Geodesic Star Convexity for Interactive Image Segmentation. In: *IEEE Conference on Computer Vision and Pattern Recognition*. 2010.
30. EVERINGHAM, Mark; VAN GOOL, Luc; WILLIAMS, Christopher KI; WINN, John; ZISSERMAN, Andrew. The pascal visual object classes (voc) challenge. *International journal of computer vision*. 2010, roč. 88, č. 2, s. 303–338.
31. RHEMANN, Christoph; ROTHER, Carsten; WANG, Jue; GELAUTZ, Margrit; KOHLI, Pushmeet; ROTT, Pamela. A perceptually motivated online benchmark for image matting. In: *2009 IEEE Conference on Computer Vision and Pattern Recognition*. 2009, s. 1826–1833.
32. WANG, G. et al. DeepIGeoS: A Deep Interactive Geodesic Framework for Medical Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2019, roč. 41, č. 7, s. 1559–1572.
33. TOIVANEN, Pekka J. New geodesic distance transforms for gray-scale images. *Pattern Recognition Letters*. 1996, roč. 17, č. 5, s. 437–450. ISSN 0167-8655. Dostupné z DOI: [https://doi.org/10.1016/0167-8655\(96\)00010-4](https://doi.org/10.1016/0167-8655(96)00010-4).
34. CIESIELSKI, Krzysztof Chris; STRAND, Robin; MALMBERG, Filip; SAHA, Punam K. Efficient algorithm for finding the exact minimum barrier distance. *Computer Vision and Image Understanding*. 2014, roč. 123, s. 53–64.
35. TIU, Ekin. *Metrics to Evaluate your Semantic Segmentation Model* [online]. 2019 [cit. 2020-03-01]. Dostupné z: <https://towardsdatascience.com/metrics-to-evaluate-your-semantic-segmentation-model-6bcb99639aa2>.
36. WIKIPEDIA CONTRIBUTORS. *Sørensen–Dice coefficient* — *Wikipedia, The Free Encyclopedia*. 2020. Dostupné také z: https://en.wikipedia.org/w/index.php?title=S%C3%B8rensen%E2%80%93Dice_coefficient&oldid=942437595. [Online; cit. 2020-3-1].
37. WIKIPEDIA CONTRIBUTORS. *Jaccard index* — *Wikipedia, The Free Encyclopedia*. 2020. Dostupné také z: https://en.wikipedia.org/w/index.php?title=Jaccard_index&oldid=943273257. [Online; cit. 2020-3-1].